



TESIS - TE142599

**ANALISIS KLASSTER KABUPATEN/KOTA
BERDASARKAN INDIKATOR PRODUK DOMESTIK
REGIONAL BRUTO (PDRB) MENGGUNAKAN
METODE *UNSUPERVISED LEARNING***

AGUNG JELANIE
2214206705

DOSEN PEMBIMBING
Dr. Supeno Mardi Susiki Nugroho, ST., MT.
Mochamad Hariadi, ST., M.Sc., Ph.D.

PROGRAM MAGISTER
BIDANG KEAHLIAN TELEMATIKA - CIO
JURUSAN TEKNIK ELEKTRO
FAKULTAS TEKNOLOGI INDUSTRI
INSTITUT TEKNOLOGI SEPULUH NOPEMBER
SURABAYA
2016



THESIS - TE142599

CLUSTER ANALYSIS OF THE DISTRICT/CITY BASED ON INDICATORS OF GROSS REGIONAL DOMESTIC PRODUCT (GRDP) USING UNSUPERVISED LEARNING

AGUNG JELANIE
2214206705

SUPERVISOR
Dr. Supeno Mardi Susiki Nugroho, ST., MT.
Mochamad Hariadi, ST., M.Sc., Ph.D.

MAGISTER PROGRAM
FIELD OF STUDY TELEMATICS - CIO
MAJOR ELECTRICAL ENGINEERING
FACULTY OF INDUSTRIAL TECHNOLOGY
INSTITUTE OF TECHNOLOGY SEPULUH NOPEMBER
SURABAYA
2016

PERNYATAAN KEASLIAN TESIS

Saya yang bertanda tangan dibawah ini:

Nama : **AGUNG JAELANIE**
Program Studi : Teknik Elektro
Bidang Keahlian : Telematika - CIO
NRP : 2214206705

Dengan ini menyatakan bahwa isi sebagian maupun keseluruhan tesis saya dengan judul:

**“ANALISIS KLASSTER KABUPATEN/KOTA BERDASARKAN
INDIKATOR PRODUK DOMESTIK REGIONAL BRUTO (PDRB)
MENGUNAKAN METODE *UNSUPERVISED LEARNING*”**

Adalah benar karya intelektual mandiri, diselesaikan tanpa menggunakan bahan-bahan yang tidak diijinkan dan bukan merupakan karya pihak lain yang saya akui sebagai karya sendiri. Semua referensi yang dikutip maupun dirujuk telah ditulis secara lengkap pada daftar pustaka. Apabila pernyataan ini tidak benar, saya bersedia menerima sanksi sesuai dengan peraturan yang berlaku.

Demikian pernyataan ini saya buat dalam keadaan sadar tanpa paksaan dari pihak manapun.

Surabaya, Juni 2016

Yang membuat pernyataan

AGUNG JAELANIE
NRP. 2214206705

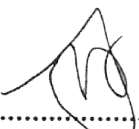
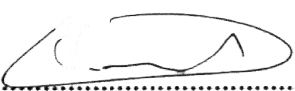
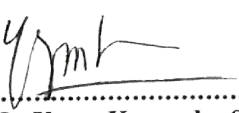
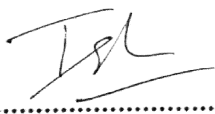
[Halaman ini sengaja dikosongkan]

LEMBAR PENGESAHAN TESIS

Tesis disusun untuk memenuhi salah satu syarat memperoleh gelar
Magister Teknik (MT)
di
Institut Teknologi Sepuluh Nopember
Oleh:
Agung Jaelanie
Nrp. 2214206705

Tanggal ujian : 23 Juni 2016
Periode wisuda : September 2016

Disetujui oleh:

1. 
.....
Dr. Supeno Mardil Susiki Nugroho, ST., MT. (Pembimbing I)
NIP. 197003131995121001
2. 
.....
Mochamad Hariadi, ST., M.Sc., Ph.D. (Pembimbing II)
NIP. 196912091997031002
3. 
.....
Dr. Ir. Yoyon Kusnendar Suprpto, M.Sc. (Penguji)
NIP. 195409251978031001
4. 
.....
Dr. Istas Pratomo, ST., MT. (Penguji)
NIP. 197903252003121001



[Halaman ini sengaja dikosongkan]

**ANALISIS KLASSTER KABUPATEN/KOTA BERDASARKAN
INDIKATOR PRODUK DOMESTIK REGIONAL BRUTO (PDRB)
MENGUNAKAN METODE *UNSUPERVISED LEARNING***

Nama Mahasiswa : Agung Jaelanie
NRP : 2214206705
Dosen Pembimbing I : Dr. Supeno Mardi Susiki Nugroho, ST., MT.
Dosen Pembimbing II : Mochamad Hariadi, ST., M.Sc., Ph.D.

ABSTRAK

Pembangunan ekonomi merupakan serangkaian usaha yang ditujukan untuk meningkatkan kesejahteraan masyarakat, mengurangi angka pengangguran, dan meminimalkan ketimpangan pendapatan di masyarakat. Ketersediaan indikator pembangunan ekonomi menjadi hal yang tidak bisa dihindari dalam perencanaan pembangunan, guna mewujudkan kebijakan yang tepat sasaran. Produk Domestik Regional Bruto (PDRB) merupakan salah satu indikator yang digunakan untuk mengetahui kondisi perekonomian di suatu wilayah. Hingga saat ini konsentrasi pembangunan perekonomian tertinggi hanya di daerah tertentu saja sehingga mengakibatkan terjadinya ketimpangan pembangunan antar daerah. Di Indonesia, penentuan alokasi dana pembangunan dalam rangka pemerataan perekonomian maupun infrastruktur di daerah masih terfokus pada satu wilayah atau daerah tertentu saja, sehingga daerah lain yang kurang mendapat perhatian dari pemerintah pusat cenderung mengalami pembangunan ekonomi yang rendah. Salah satu penyebab adanya ketidakseimbangan pembangunan ekonomi adalah keterbatasan data dan informasi mengenai pola perekonomian dan daerah yang masih rendah tingkat perekonomiannya, sehingga dimungkinkan terjadi kesalahan dalam menentukan prioritas kebijakan. Tujuan penelitian ini adalah menghasilkan pola perekonomian dan mengetahui daerah yang masih rendah tingkat perekonomiannya berdasarkan data PDRB sehingga bisa digunakan sebagai dasar untuk menentukan prioritas kebijakan pembangunan ekonomi di daerah. Pendekatan analisis yang dilakukan adalah analisis kluster. Metode yang digunakan adalah metode *K-Means* dan *Self-Organizing Maps (SOM)*. Penelitian ini menghasilkan 7 kluster sebagai yang terbaik menggunakan metode SOM dengan nilai validasi sebesar 0.9704.

Kata kunci : Klustering, Produk Domestik Regional Bruto (PDRB), *K-Means*, *Self-Organizing Maps (SOM)*

[Halaman ini sengaja dikosongkan]

**CLUSTER ANALYSIS OF THE DISTRICT/CITY BASED ON
INDICATORS OF GROSS REGIONAL DOMESTIC PRODUCT (GRDP)
USING UNSUPERVISED LEARNING**

Name : Agung Jaelanie
NRP : 2214206705
Supervisor : Dr. Supeno Mardi Susiki Nugroho, ST., MT.
Co-Supervisor : Mochamad Hariadi, ST., M.Sc., Ph.D.

ABSTRACT

Economic development is a series of efforts which is intended for improving people's welfare, reduce the unemployment, and minimize inequality in society. The willingness of economic development indicators becomes unavoidable in development planning. In order to get the right policy which is targeted, gross regional domestic product (GRDP) is one of the indicators used to know the economic conditions in a region. So far, The highest concentration of economic development which only in certain areas have caused imbalance of economic development between regions. In Indonesia, determining the allocation of development funds in the context of equitable economy and infrastructure in the region is still focused on a certain region or area, thus other areas receive less attention from the central government tend to experience low economic development. One of the causes which makes imbalance of economic development is the limited of data and information about the pattern of the economy and the area which is still has low economy, so it is possible there will be an error in determining policy priorities. The purposed of the research is to produce the economy pattern and to know the areas that have low levels of the economy based on the gross regional domestic product (GRDP) so the research can be used as the basis for determining the priority of economic development policy in the region. Analytical approach in doing is cluster analysis. The methods used is the K-Means method and Self-Organizing Maps (SOM). This research has resulted 7 clusters as the best method SOM validation value of 0.9704.

Keyword : Clustering, Gross Regional Domestic Product, *K-Means*, *Self-Organizing Maps (SOM)*

[Halaman ini sengaja dikosongkan]

DAFTAR ISI

HALAMAN SAMPUL	i
PERNYATAAN KEASLIAN TESIS	iii
LEMBAR PENGESAHAN TESIS	iv
ABSTRAK	v
ABSTRACT	vii
KATA PENGANTAR	ix
DAFTAR ISI	xi
DAFTAR GAMBAR	xiii
DAFTAR TABEL	xv
DAFTAR ISTILAH	xix
BAB 1 PENDAHULUAN	1
1.1 Latar Belakang	1
1.2 Rumusan Masalah	3
1.3 Tujuan Penelitian	3
1.4 Manfaat Penelitian	3
1.5 Batasan Penelitian	3
BAB 2 TINJAUAN PUSTAKA	5
2.1 Produk Domestik Regional Bruto (PDRB)	5
2.2 Perubahan Tahun Dasar PDRB.....	5
2.3 Sektor PDRB Menurut Lapangan Usaha	7
2.4 Manfaat PDRB	13
2.5 Data Mining	14
2.6 Tahap Data Mining	15
2.7 Normalisasi Data PDRB.....	17
2.8 Analisis Kluster	18
2.9 Algoritma <i>K-Means</i>	19
2.10 <i>Self-Organizing Maps (SOM)</i>	23
2.11 Validasi Kluster	25
2.12 Visualisasi Informasi	28

BAB 3 METODOLOGI PENELITIAN	31
3.1 Alur Penelitian	31
3.2 Pengambilan dan Mempersiapkan Data PDRB	32
3.3 Persiapan Data	32
3.4 Normalisasi Data	32
3.5 Klastering Kabupaten/Kota Menggunakan <i>K-means</i>	36
3.6 Klastering Kabupaten/Kota Menggunakan <i>SOM</i>	37
3.7 Validasi Klaster Menggunakan DBI	37
3.8 Penentuan Jumlah Klaster Terbaik	38
3.9 Analisis Klaster Terbaik	38
3.10 Informasi dan Pengetahuan	38
BAB 4 HASIL DAN PEMBAHASAN	39
4.1 Hasil Uji Coba Klaster	39
4.1.1 Hasil Klastering Menggunakan <i>K-Means</i>	39
4.1.2 Hasil Klastering Menggunakan <i>SOM</i>	48
4.2 Hasil Validasi Klaster dan Penentuan Klaster Terbaik	57
4.3 Visualisasi dan Analisis Hasil Klaster	58
4.3.1 Visualisasi dan Analisis Berdasarkan Seluruh Indikator PDRB ...	58
4.3.2 Visualisasi dan Analisis Berdasarkan Masing-Masing Indikator	
PDRB	63
BAB 5 KESIMPULAN	89
5.1 Kesimpulan	89
DAFTAR PUSTAKA	91

DAFTAR GAMBAR

Gambar 2.1 Tahap Pada Data Mining	16
Gambar 2.2 Ilustrasi Klastering	19
Gambar 2.3 Arsitektur <i>SOM</i>	24
Gambar 2.4 Klasifikasi Teknik Visualisasi Informasi	29
Gambar 2.5 Teknik Koordinat Paralel	29
Gambar 2.6 Teknik Visualisasi Data Berdimensi Tiga	29
Gambar 3.1 Alur Metodologi Penelitian	31
Gambar 4.1 Grafik Nilai <i>DBI</i> 3 sampai 10 Klaster	57
Gambar 4.2 Grafik <i>u-matrix</i> Seluruh Indikator	59
Gambar 4.3 Distribusi Data Seluruh Indikator	59
Gambar 4.4 Visualisasi Klaster 1	60
Gambar 4.5 Visualisasi Klaster 2	60
Gambar 4.6 Visualisasi Klaster 3	61
Gambar 4.7 Visualisasi Klaster 4	61
Gambar 4.8 Visualisasi Klaster 5	62
Gambar 4.9 Visualisasi Klaster 6	62
Gambar 4.10 Visualisasi Klaster 7	63
Gambar 4.11 Grafik <i>u-matrix</i> Indikator Pertanian	64
Gambar 4.12 Peta Distribusi Data Indikator Pertanian	64
Gambar 4.13 Grafik <i>u-matrix</i> Indikator Pertambangan	65
Gambar 4.14 Peta Distribusi Data Indikator Pertambangan	66
Gambar 4.15 Grafik <i>u-matrix</i> Indikator Industri Pengolahan	67
Gambar 4.16 Peta Distribusi Data Indikator Industri Pengolahan	67
Gambar 4.17 Grafik <i>u-matrix</i> Indikator Pengadaan Listrik dan Gas	68
Gambar 4.18 Peta Distribusi Data Indikator Pengadaan Listrik dan Gas	69
Gambar 4.19 Grafik <i>u-matrix</i> Indikator Pengadaan Air	70
Gambar 4.20 Peta Distribusi Data Indikator Pengadaan Air	70
Gambar 4.21 Grafik <i>u-matrix</i> Indikator Konstruksi	71
Gambar 4.22 Peta Distribusi Data Indikator Konstruksi	71
Gambar 4.23 Grafik <i>u-matrix</i> Indikator Perdagangan	73

Gambar 4.24 Peta Distribusi Data Indikator Perdagangan	73
Gambar 4.25 Grafik <i>u-matrix</i> Indikator Transportasi	74
Gambar 4.26 Peta Distribusi Data Indikator Transportasi	75
Gambar 4.27 Grafik <i>u-matrix</i> Indikator Akomodasi Makan	76
Gambar 4.28 Peta Distribusi Data Indikator Akomodasi Makan	76
Gambar 4.29 Grafik <i>u-matrix</i> Indikator Informasi Komunikasi	77
Gambar 4.30 Peta Distribusi Data Indikator Informasi Komunikasi	78
Gambar 4.31 Grafik <i>u-matrix</i> Indikator Jasa Keuangan	79
Gambar 4.32 Peta Distribusi Data Indikator Jasa Keuangan	79
Gambar 4.33 Grafik <i>u-matrix</i> Indikator Real Estate	80
Gambar 4.34 Peta Distribusi Data Indikator Real Estate	81
Gambar 4.35 Grafik <i>u-matrix</i> Indikator Jasa Perusahaan	82
Gambar 4.36 Peta Distribusi Data Indikator Jasa Perusahaan	82
Gambar 4.37 Grafik <i>u-matrix</i> Indikator Administrasi Pemerintahan	83
Gambar 4.38 Peta Distribusi Data Indikator Administrasi Pemerintahan	83
Gambar 4.39 Grafik <i>u-matrix</i> Indikator Jasa Pendidikan	84
Gambar 4.40 Peta Distribusi Data Indikator Jasa Pendidikan	85
Gambar 4.41 Grafik <i>u-matrix</i> Indikator Jasa Kesehatan	86
Gambar 4.42 Peta Distribusi Data Indikator Jasa Kesehatan	86
Gambar 4.43 Grafik <i>u-matrix</i> Indikator Jasa Lainnya	87
Gambar 4.44 Peta Distribusi Data Indikator Jasa Lainnya	88

DAFTAR TABEL

Tabel 2.1 Perbandingan Perubahan PDRB Menurut Lapangan Usaha Tahun Dasar 2000 dan 2010	6
Tabel 3.1 Data PDRB Sebelum Normalisasi (Dalam Milyar Rupiah)	32
Tabel 3.2 Nilai Minimum dan Maksimum Masing-Masing Indikator PDRB	33
Tabel 3.3 Data PDRB Setelah Normalisasi	34
Tabel 3.4 Nilai Rata-Rata Indikator PDRB	35
Tabel 4.1 <i>Centroid</i> Akhir 3 Klaster	39
Tabel 4.2 Distribusi Data 3 Klaster	39
Tabel 4.3 Rasio Klaster	40
Tabel 4.4 <i>Centroid</i> Akhir 4 Klaster	40
Tabel 4.5 Distribusi Data 4 Klaster	40
Tabel 4.6 Rasio Klaster	41
Tabel 4.7 <i>Centroid</i> Akhir 5 Klaster	41
Tabel 4.8 Distribusi Data 5 Klaster	41
Tabel 4.9 Rasio Klaster	42
Tabel 4.10 <i>Centroid</i> Akhir 6 Klaster	42
Tabel 4.11 Distribusi Data 6 Klaster	43
Tabel 4.12 Rasio Klaster	43
Tabel 4.13 <i>Centroid</i> Akhir 7 Klaster	43
Tabel 4.14 Distribusi Data 7 Klaster	44
Tabel 4.15 Rasio Klaster	44
Tabel 4.16 <i>Centroid</i> Akhir 8 Klaster	45
Tabel 4.17 Distribusi Data 8 Klaster	45
Tabel 4.18 Rasio Klaster	45
Tabel 4.19 <i>Centroid</i> Akhir 9 Klaster	46
Tabel 4.20 Distribusi Data 9 Klaster	46
Tabel 4.21 Rasio Klaster	47
Tabel 4.22 <i>Centroid</i> Akhir 10 Klaster	47
Tabel 4.23 Distribusi Data 10 Klaster	47
Tabel 4.24 Rasio Klaster	48

Tabel 4.25 Bobot Akhir 3 Klaster	48
Tabel 4.26 Distribusi Data 3 Klaster dan Nilai <i>DBI</i>	49
Tabel 4.27 Bobot Akhir 4 Klaster	49
Tabel 4.28 Distribusi Data 4 Klaster dan Nilai <i>DBI</i>	50
Tabel 4.29 Bobot Akhir 5 Klaster	50
Tabel 4.30 Distribusi Data 5 Klaster dan Nilai <i>DBI</i>	51
Tabel 4.31 Bobot Akhir 6 Klaster	51
Tabel 4.32 Distribusi Data 6 Klaster dan Nilai <i>DBI</i>	52
Tabel 4.33 Bobot Akhir 7 Klaster	52
Tabel 4.34 Distribusi Data 7 Klaster dan Nilai <i>DBI</i>	53
Tabel 4.35 Bobot Akhir 8 Klaster	53
Tabel 4.36 Distribusi Data 8 Klaster dan Nilai <i>DBI</i>	54
Tabel 4.37 Bobot Akhir 9 Klaster	55
Tabel 4.38 Distribusi Data 9 Klaster dan Nilai <i>DBI</i>	55
Tabel 4.39 Bobot Akhir 10 Klaster	56
Tabel 4.40 Distribusi Data 10 Klaster dan Nilai <i>DBI</i>	56
Tabel 4.41 Nilai <i>DBI</i> 3 sampai 10 Klaster	57
Tabel 4.42 Parameter Peta Jaringan <i>SOM</i>	58
Tabel 4.43 Bobot Akhir 7 Klaster	58
Tabel 4.44 Distribusi Data 7 Klaster	59
Tabel 4.45 Nilai <i>DBI</i> Indikator Pertanian	63
Tabel 4.46 Bobot Akhir dan Distribusi Data 3 Klaster	64
Tabel 4.47 Nilai <i>DBI</i> Indikator Pertambangan.....	65
Tabel 4.48 Bobot Akhir dan Distribusi Data 5 Klaster	65
Tabel 4.49 Nilai <i>DBI</i> Indikator Industri Pengolahan.....	66
Tabel 4.50 Bobot Akhir dan Distribusi Data 4 Klaster	67
Tabel 4.51 Nilai <i>DBI</i> Indikator Pengadaan Listrik dan Gas	68
Tabel 4.52 Bobot Akhir dan Distribusi Data 6 Klaster	68
Tabel 4.53 Nilai <i>DBI</i> Indikator Pengadaan Air.....	69
Tabel 4.54 Bobot Akhir dan Distribusi Data 4 Klaster	69
Tabel 4.55 Nilai <i>DBI</i> Indikator Konstruksi.....	70
Tabel 4.56 Bobot Akhir dan Distribusi Data 3 Klaster	71

Tabel 4.57 Nilai <i>DBI</i> Indikator Perdagangan.....	72
Tabel 4.58 Bobot Akhir dan Distribusi Data 3 Klaster	72
Tabel 4.59 Nilai <i>DBI</i> Indikator Transportasi	73
Tabel 4.60 Bobot Akhir dan Distribusi Data 10 Klaster	74
Tabel 4.61 Nilai <i>DBI</i> Indikator Penyediaan Akomodasi Makan.....	75
Tabel 4.62 Bobot Akhir dan Distribusi Data 3 Klaster	75
Tabel 4.63 Nilai <i>DBI</i> Indikator Informasi Komunikasi.....	76
Tabel 4.64 Bobot Akhir dan Distribusi Data 7 Klaster	77
Tabel 4.65 Nilai <i>DBI</i> Indikator Jasa keuangan.....	78
Tabel 4.66 Bobot Akhir dan Distribusi Data 5 Klaster	79
Tabel 4.67 Nilai <i>DBI</i> Indikator Real Estate	80
Tabel 4.68 Bobot Akhir dan Distribusi Data 5 Klaster	80
Tabel 4.69 Nilai <i>DBI</i> Indikator Jasa Perusahaan.....	81
Tabel 4.70 Bobot Akhir dan Distribusi Data 4 Klaster	81
Tabel 4.71 Nilai <i>DBI</i> Indikator Administrasi Pemerintahan.....	82
Tabel 4.72 Bobot Akhir dan Distribusi Data 7 Klaster	83
Tabel 4.73 Nilai <i>DBI</i> Indikator Jasa pendidikan	84
Tabel 4.74 Bobot Akhir dan Distribusi Data 6 Klaster	84
Tabel 4.75 Nilai <i>DBI</i> Indikator Jasa Kesehatan	85
Tabel 4.76 Bobot Akhir dan Distribusi Data 9 Klaster	85
Tabel 4.77 Nilai <i>DBI</i> Indikator Jasa Lainnya.....	87
Tabel 4.78 Bobot Akhir dan Distribusi Data 6 Klaster	87

[Halaman ini sengaja dikosongkan]

DAFTAR ISTILAH

<i>Centroid</i>	titik pusat hasil proses klastering menggunakan <i>K-Means</i> .
Data	sesuatu yang menunjukkan perbandingan nilai aktual pada sebuah proses data mining.
Data mining	adalah kegiatan yang meliputi pengumpulan, pemakaian data historis untuk menemukan keteraturan, pola atau hubungan dalam set data berukuran besar.
Informasi	hasil pengolahan dari sebuah model, formasi, organisasi, ataupun suatu perubahan bentuk dari data yang memiliki nilai tertentu, dan bisa digunakan untuk menambah pengetahuan bagi yang menerimanya. Dalam hal ini, data bisa dianggap sebagai objek dan informasi adalah suatu subjek yang bermanfaat bagi penerimanya. Informasi juga bisa disebut sebagai hasil pengolahan ataupun pemroses data.
Klaster	pengelompokkan data-data ke dalam sejumlah kelompok berdasarkan kesamaan karakteristik masing-masing data pada kelompok-kelompok yang ada. Data-data yang masuk dalam batas kesamaan dengan kelompoknya akan bergabung dalam kelompok tersebut, dan akan terpisah dalam kelompok yang berbeda jika keluar dari batas kesamaan dengan kelompok tersebut.
<i>K-Means</i>	merupakan algoritma yang digunakan untuk mengelompokkan iterative, algoritma ini melakukan partisi set data ke dalam sejumlah K klaster yang sudah ditetapkan dari awal. Partisi set data tersebut dilakukan untuk mengetahui karakteristik dari setiap klaster, sehingga klaster yang memiliki karakteristik sama dikelompokkan ke dalam satu klaster dan yang memiliki karakteristik berbeda dikelompokkan ke dalam klaster lain.
Metode	cara, pendekatan.

Normalisasi	normalisasi adalah proses dua langkah yang meletakkan data dalam bentuk tabulasi dengan menghilangkan kelompok berulang lalu menghilangkan data yang terduplikasi.
PDRB	Produk Domestik Regional Bruto, merupakan salah satu indikator yang digunakan untuk mengetahui kondisi perekonomian suatu wilayah seperti pertanian, pertambangan, industri, perdagangan dan sebagainya.
<i>Self-Organizing Maps (SOM)</i>	merupakan generalisasi dari jaringan kompetitif, dan merupakan jaringan tanpa supervise. disusun oleh sebuah lapisan unit input yang dihubungkan seluruhnya ke lapisan unit output, yang kemudian unit-unit diatur di dalam topologi khusus seperti struktur jaringan.
Validasi	suatu skala atau pengukuran dari hasil proses pengolahan data dalam data mining.
Visualisasi	merupakan rekayasa dalam pembuatan gambar, diagram atau animasi untuk penampilan suatu informasi.
DBI	Hasil validasi cluster
\hat{x}_{yz}	Hasil normalisasi data
$R_{i,j}$	Rasio antar cluster ke i dan j
$SSB_{i,j}$	Jarak antar cluster ke i dan j
SSW_i	Jarak antar data ke i
c_j	Centroid baru pada klaster ke j
c_{jk}	Centroid ke j pada indikator ke k
$d_{(i,j)}$	Jarak data ke <i>centroid</i>
w_{ij}	Bobot data i ke j
x_{ik}	Data ke i pada indikator ke k
σ_z^2	Varian data
$d(c_i, c_j)$	Jarak antar cluster c_i dan c_j
$\max(x_z)$	Nilai maksimal data ke z
$\min(x_z)$	Nilai minimal data ke z

BAB 1

PENDAHULUAN

1.1 Latar Belakang

Pembangunan ekonomi merupakan serangkaian usaha yang ditujukan untuk meningkatkan kesejahteraan masyarakat, mengurangi angka pengangguran, dan meminimalkan ketimpangan pendapatan di masyarakat. Pembangunan ekonomi akan berjalan efektif dan efisien ketika berpijak pada perencanaan pembangunan yang tepat sasaran. Ketersediaan indikator pembangunan ekonomi menjadi hal yang tidak bisa dihindari dalam perencanaan pembangunan, guna mewujudkan kebijakan yang tepat sasaran. Selain itu evaluasi kebijakan juga diperlukan untuk memperbaiki perencanaan pembangunan di masa yang akan datang (BPS, 2015). Salah satunya aspek yang harus dipertimbangkan adalah pembangunan perekonomian seluruh wilayah di Indonesia.

Hingga saat ini konsentrasi pembangunan perekonomian tertinggi hanya di daerah tertentu saja sehingga mengakibatkan terjadinya ketimpangan pembangunan antar daerah. Ekonomi dari daerah dengan konsentrasi kegiatan ekonomi tinggi cenderung tumbuh pesat. Sedangkan daerah dengan tingkat konsentrasi ekonomi rendah cenderung mempunyai tingkat pembangunan ekonomi yang lebih rendah. Secara umum strategi pembangunan ekonomi nasional yang diterapkan selama pemerintahan orde baru sampai reformasi membuat secara langsung maupun tidak langsung terpusatnya pembangunan ekonomi di Jawa, khususnya Jawa Barat dan Jawa Timur, dan hingga tingkat tertentu di Sumatera (Arsyad, 2010).

Salah satu contohnya adalah propinsi Jawa Timur yang terdiri atas 38 Kabupaten/Kota, dimana setiap Kabupaten/Kota memiliki pertumbuhan ekonomi masing-masing. Jawa Timur merupakan penyumbang pembangunan terbesar ke dua dalam perekonomian nasional setelah DKI Jakarta dengan kontribusi sebesar 14,40 persen pada tahun 2014. Data dari Badan Pusat Statistik (BPS) tiga kategori paling mendominasi perekonomian Provinsi Jawa Timur adalah kategori industri pengolahan (28,90 persen), kategori perdagangan besar dan eceran, reparasi mobil dan sepeda motor (17,24 persen), dan kategori pertanian (13,73 persen). Ketiga

kategori tersebut menyumbang 59,87 persen dari perekonomian Jawa Timur (BPS, 2015).

Di Indonesia, penentuan alokasi dana pembangunan dalam rangka pemerataan perekonomian maupun infrastruktur di daerah masih terfokus pada satu wilayah atau daerah tertentu saja sehingga setiap tahun daerah lain yang kurang mendapat perhatian dari pemerintah pusat mengalami pertumbuhan ekonomi yang rendah pula. Salah satu penyebab adanya ketidakseimbangan pembangunan ekonomi adalah keterbatasan data dan informasi mengenai pola perekonomian di daerah sehingga dimungkinkan terjadi kesalahan dalam menentukan arah kebijakan perekonomian daerah yang mengakibatkan program yang telah dipersiapkan menjadi tidak tepat sasaran (Sjafrizal, 2012). Untuk mengatasi permasalahan tersebut diperlukan berbagai macam data dan informasi agar dalam menentukan strategi dan arah kebijakan pembangunan ekonomi lebih tepat sasaran salah satunya adalah Produk Domestik Regional Bruto (BPS, 2015).

PDRB merupakan salah satu indikator yang digunakan untuk mengetahui kondisi perekonomian suatu wilayah seperti pertanian, pertambangan, industri, perdagangan dan sebagainya. Pada penelitian ini, peneliti mencoba mengeksplor lebih jauh data PDRB menggunakan pendekatan data mining untuk mendapatkan pola perekonomian di daerah di Indonesia. Sehingga diketahui daerah-daerah yang memiliki tingkat perekonomian rendah untuk mendapatkan prioritas kebijakan pembangunan ekonomi. Data mining sendiri merupakan metode pengolahan berdasarkan data dengan beberapa teknik pengolahan untuk mendapatkan informasi yang tersembunyi salah satunya yaitu analisis klaster. Pendekatan metode yang digunakan adalah metode *K-Means* dan *Self-Organizing Maps (SOM)*. *K-Means* dan *SOM* adalah metode yang bisa digunakan untuk melakukan analisis klaster pada data yang belum diketahui pola klasternya. Data akan diklaster berdasarkan indikator PDRB. Akhir dari penelitian ini diharapkan mendapatkan informasi tentang pola perekonomian di daerah yang bisa dijadikan sebagai bahan pertimbangan dalam menentukan kebijakan, merencanakan kegiatan, membuat program peningkatan kesejahteraan serta mengurangi ketimpangan pendapatan antar daerah secara proporsional, akurat dan berkelanjutan yang berujung pada kesejahteraan masyarakat.

1.2 Rumusan Masalah

Permasalahan yang diangkat pada penelitian ini adalah kebijakan pemerintah pusat terkait pembangunan ekonomi dianggap belum tepat sasaran, karena keterbatasan data dan informasi tentang pola perekonomian di seluruh wilayah di Indonesia.

1.3 Tujuan Penelitian

Tujuan yang akan dicapai pada penelitian ini adalah menghasilkan kluster data berdasarkan indikator PDRB sehingga diketahui daerah-daerah yang memiliki tingkat perekonomian rendah untuk mendapatkan proiritas kebijakan pembangunan ekonomi menggunakan metode *Unsupervised Learning*.

1.4 Manfaat Penelitian

Bagi instansi terkait, hasil penelitian ini diharapkan bisa sebagai bahan pertimbangan dalam menentukan kebijakan, merencanakan kegiatan, membuat program peningkatan kesejahteraan serta mengurangi ketimpangan pendapatan antar daerah secara proporsional, akurat dan berkelanjutan yang berujung pada kesejahteraan masyarakat.

1.5 Batasan Penelitian

Penelitian ini hanya dibatasi pada data yang digunakan adalah data PDRB menurut lapangan usaha yang didapatkan dari Badan Pusat Statistik (BPS). Indikator yang digunakan berdasarkan tahun dasar 2010. Metode pengelompokan yang digunakan adalah *K-Means* dan *Self-Organizing Maps (SOM)*.

[Halaman ini sengaja dikosongkan]

BAB 2

TINJAUAN PUSTAKA

2.1 Produk Domestik Regional Bruto (PDRB)

Salah satu indikator penting untuk mengetahui kondisi perekonomian di suatu daerah dalam periode tertentu adalah data Produk Domestik Regional Bruto (PDRB), baik atas dasar harga berlaku maupun atas dasar harga konstan. PDRB pada dasarnya merupakan jumlah nilai tambah yang dihasilkan oleh seluruh unit usaha dalam suatu daerah tertentu, atau merupakan jumlah nilai barang dan jasa akhir yang dihasilkan oleh seluruh unit ekonomi.

PDRB merupakan nilai tambah bruto seluruh barang dan jasa yang tercipta atau dihasilkan di wilayah domestik suatu negara yang timbul akibat berbagai aktivitas ekonomi dalam suatu periode tertentu tanpa memperhatikan apakah faktor produksi yang dimiliki residen atau non-residen. Semakin besar nilai PDRB yang dihasilkan maka perekonomian di daerah tersebut tinggi begitu sebaliknya. Penyusunan PDRB dapat dilakukan melalui 3 (tiga) pendekatan yaitu pendekatan produksi, pengeluaran, dan pendapatan yang disajikan atas dasar harga berlaku dan harga konstan (riil).

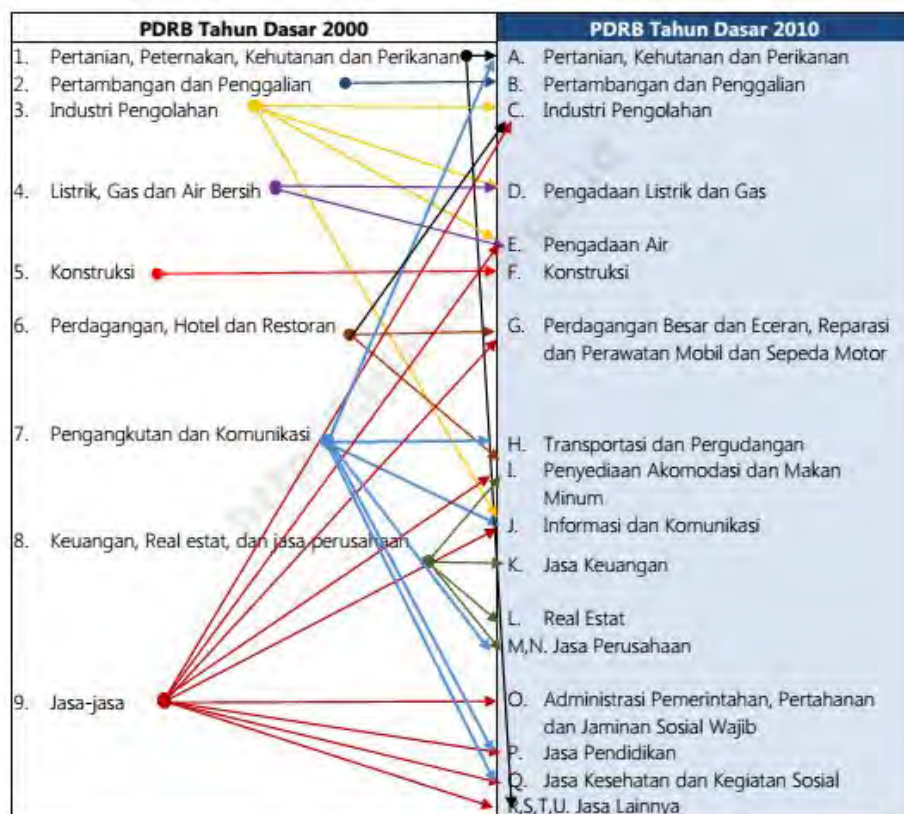
PDRB atas dasar harga berlaku atau dikenal dengan PDRB nominal disusun berdasarkan harga yang berlaku pada periode penghitungan, dan bertujuan untuk melihat struktur perekonomian. Sedangkan PDRB atas dasar harga konstan (riil) disusun berdasarkan harga pada tahun dasar dan bertujuan untuk mengukur pertumbuhan ekonomi (BPS, 2015).

2.2 Perubahan Tahun Dasar PDRB

Selama sepuluh tahun terakhir, banyak perubahan yang terjadi pada tatanan global dan local yang sangat berpengaruh terhadap perekonomian nasional. Krisis finansial global yang terjadi pada tahun 2008, penerapan perdagangan bebas antara China-ASEAN (CAFTA), perubahan system pencatatan perdagangan internasional dan meluasnya jasa layanan pasar modal merupakan contoh perubahan yang perlu diadaptasi dalam mekanisme pencatatan statistik nasional.

Salah satu bentuk adaptasi pencatatan statistik nasional adalah melakukan perubahan tahun dasar PDB Indonesia dari tahun 2000 ke 2010. Perubahan tahun dasar PDB dilakukan seiring dengan mengadopsi rekomendasi Perserikatan Bangsa-Bangsa (PBB) yang tertuang dalam 2008 *System of National Accounts* (SNA 2008) melalui penyusunan kerangka *Supply and Use Tables* (SUT). Perubahan tahun dasar PDB dilakukan secara bersamaan dengan penghitungan Produk Domestik Regional Bruto (PDRB) Provinsi untuk menjaga konsistensi hasil penghitungan.

Tabel 2.1 Perbandingan Perubahan PDRB Menurut Lapangan Usaha Tahun Dasar 2000 dan 2010



2.2.1 Manfaat Perubahan Tahun Dasar

Manfaat perubahan tahun dasar PDRB antara lain :

1. Menginformasikan perekonomian regional yang terkini seperti pergeseran struktur dan pertumbuhan ekonomi.
2. Meningkatkan kualitas data PDRB.
3. Menjadikan data PDRB dapat diperbandingkan secara internasional.

2.2.2 Tahun 2010 Sebagai Tahun Dasar

Badan Pusat Statistik (BPS) telah melakukan perubahan tahun dasar secara berkala sebanyak 5 (lima) kali yaitu pada tahun 1960, 1973, 1983, 1993, dan 2000. Tahun 2010 dipilih sebagai tahun dasar baru menggantikan tahun dasar 2000 karena beberapa alasan berikut:

1. Perekonomian Indonesia tahun 2010 relatif stabil.
2. Telah terjadi perubahan struktur ekonomi selama 10 (sepuluh) tahun terakhir terutama dibidang informasi dan teknologi serta transportasi yang berpengaruh terhadap pola distribusi dan munculnya produk-produk baru;
3. Rekomendasi PBB tentang pergantian tahun dasar dilakukan setiap 5 (lima) atau 10 (sepuluh) tahun 1.
4. Adanya pembaharuan konsep, definisi, klasifikasi, cakupan, sumber data dan metodologi sesuai rekomendasi dalam SNA 2008.
5. Tersedianya sumber data baru untuk perbaikan PDRB seperti data Sensus Penduduk 2010 (SP 2010) dan Indeks harga produsen (*Producers Price Index* /PPI).
6. Tersedianya kerangka kerja SUT yang menggambarkan keseimbangan aliran produksi dan konsumsi (barang dan jasa) dan penciptaan pendapatan dari aktivitas produksi tersebut.

2.3 Sektor PDRB Menurut Lapangan Usaha

PDRB menurut lapangan usaha tahun dasar 2000 menggunakan Klasifikasi Lapangan Usaha Indonesia 1990 (KLUI 1990) sedangkan pada PDRB tahun dasar 2010 menggunakan KBLI 2009^[1].

1. Pertanian

Kategori ini mencakup segala pengusahaan yang didapatkan dari alam dan merupakan benda-benda atau barang-barang biologis (hidup) yang hasilnya dapat digunakan untuk memenuhi kebutuhan hidup sendiri atau untuk dijual kepada pihak lain. Pengusahaan ini termasuk kegiatan yang tujuannya utamanya untuk memenuhi kebutuhan sendiri (subsisten) seperti pada kegiatan usaha tanaman pangan.

2. Pertambangan

Seluruh jenis komoditi yang dicakup dalam Kategori Pertambangan dan Penggalian, dikelompokkan dalam empat subkategori, yaitu: pertambangan minyak dan gas bumi (migas), pertambangan batubara dan lignit, pertambangan bijih logam serta pertambangan dan penggalian lainnya.

3. Industri Pengolahan

Kategori Industri Pengolahan meliputi kegiatan ekonomi di bidang perubahan secara kimia atau fisik dari bahan, unsur atau komponen menjadi produk baru. Bahan baku industri pengolahan berasal dari produk pertanian, kehutanan, perikanan, pertambangan atau penggalian seperti produk dari kegiatan industri pengolahan lainnya. Perubahan, pembaharuan atau rekonstruksi yang pokok dari barang secara umum diperlakukan sebagai industri pengolahan. Unit industri pengolahan digambarkan sebagai pabrik, mesin atau peralatan yang khusus digerakkan dengan mesin dan tangan. Termasuk kategori industri pengolahan adalah perubahan bahan menjadi produk baru dengan menggunakan tangan, kegiatan maklon atau kegiatan penjualan produk yang dibuat di tempat yang sama dimana produk tersebut dijual dan unit yang melakukan pengolahan bahan-bahan dari pihak lain atas dasar kontrak.

4. Pengadaan Listrik dan Gas

Kategori ini mencakup kegiatan pengadaan tenaga listrik, gas alam dan buatan, uap panas, air panas, udara dingin dan produksi es dan sejenisnya melalui jaringan, saluran, atau pipa infrastruktur permanen. Dimensi jaringan/infrastruktur

tidak dapat ditentukan dengan pasti, termasuk kegiatan pendistribusian listrik, gas, uap panas dan air panas serta pendinginan udara dan air untuk tujuan produksi es. Produksi es untuk kebutuhan makanan/minuman dan tujuan non makanan. Kategori ini juga mencakup pengoperasian mesin dan gas yang menghasilkan, mengontrol dan menyalurkan tenaga listrik atau gas. Juga mencakup pengadaan uap panas dan AC.

5. Pengadaan Air dan Pengelolaan Sampah

Kategori ini mencakup kegiatan ekonomi/lapangan usaha yang berhubungan dengan pengelolaan berbagai bentuk limbah/sampah, seperti limbah/sampah padat atau bukan baik rumah tangga ataupun industri, yang dapat mencemari lingkungan. Hasil dari proses pengelolaan limbah sampah atau kotoran ini dibuang atau menjadi input dalam proses produksi lainnya. Kegiatan pengadaan air termasuk kategori ini, karena kegiatan ini sering kali dilakukan dalam hubungannya dengan atau oleh unit yang terlibat dalam pengelolaan limbah/kotoran.

6. Konstruksi

Kategori Konstruksi adalah kegiatan usaha di bidang konstruksi umum dan konstruksi khusus pekerjaan gedung dan bangunan sipil, baik digunakan sebagai tempat tinggal atau sarana kegiatan lainnya. Kegiatan konstruksi mencakup pekerjaan baru, perbaikan, penambahan dan perubahan, pendirian prafabrikasi bangunan atau struktur di lokasi proyek dan juga konstruksi yang bersifat sementara. Kegiatan konstruksi dilakukan baik oleh kontraktor umum, yaitu perusahaan yang melakukan pekerjaan konstruksi untuk pihak lain, maupun oleh kontraktor khusus, yaitu unit usaha atau individu yang melakukan kegiatan konstruksi untuk dipakai sendiri.

7. Perdagangan

Kategori ini meliputi kegiatan ekonomi/lapangan usaha di bidang perdagangan besar dan eceran (yaitu penjualan tanpa perubahan teknis) dari berbagai jenis barang, dan memberikan imbalan jasa yang mengiringi penjualan

barang-barang tersebut. Baik penjualan secara grosir (perdagangan besar) maupun eceran merupakan tahap akhir dalam pendistribusian barang dagangan. Kategori ini juga mencakup reparasi mobil dan sepeda motor.

8. Transportasi dan Pergudangan

Kategori ini mencakup penyediaan angkutan penumpang atau barang, baik yang berjadwal maupun tidak, dengan menggunakan rel, saluran pipa, jalan darat, air atau udara dan kegiatan yang berhubungan dengan pengangkutan. Kategori Transportasi dan Pergudangan terdiri atas: angkutan rel; angkutan darat; angkutan laut; angkutan sungai, danau dan penyeberangan; angkutan udara; pergudangan dan jasa penunjang angkutan, pos dan kurir. Kegiatan pengangkutan meliputi kegiatan pemindahan penumpang dan barang dari suatu tempat ke tempat lainnya dengan menggunakan alat angkut atau kendaraan, baik bermotor maupun tidak bermotor. Sedangkan jasa penunjang angkutan mencakup kegiatan yang sifatnya menunjang kegiatan pengangkutan seperti: terminal, pelabuhan, pergudangan, dan lain-lain.

9. Penyediaan Akomodasi dan Makan Minum

Kategori ini mencakup penyediaan akomodasi penginapan jangka pendek untuk pengunjung dan pelancong lainnya serta penyediaan makanan dan minuman untuk konsumsi segera. Jumlah dan jenis layanan tambahan yang disediakan sangat bervariasi. Tidak termasuk penyediaan akomodasi jangka panjang seperti tempat tinggal utama, penyiapan makanan atau minuman bukan untuk dikonsumsi segera atau yang melalui kegiatan perdagangan besar dan eceran.

10. Informasi dan Komunikasi

Kategori ini mencakup produksi dan distribusi informasi dan produk kebudayaan, persediaan alat untuk mengirimkan atau mendistribusikan produk-produk ini dan juga data atau kegiatan komunikasi, informasi, teknologi informasi dan pengolahan data serta kegiatan jasa informasi lainnya. Kategori terdiri dari beberapa industri yaitu Penerbitan, Produksi Gambar Bergerak, Video, Perekaman

Suara dan Penerbitan Musik, Penyiaran dan Pemograman (Radio dan Televisi), Telekomunikasi, Pemograman, Konsultasi Komputer dan Teknologi Informasi.

11. Jasa Keuangan

Kategori ini mencakup jasa perantara keuangan, asuransi dan pensiun, jasa keuangan lainnya serta jasa penunjang keuangan. Kategori ini juga mencakup kegiatan pemegang asset, seperti kegiatan perusahaan holding dan kegiatan dari lembaga penjaminan atau pendanaan dan lembaga keuangan sejenis.

12. Real Estat

Kategori ini meliputi kegiatan persewaan, agen dan atau perantara dalam penjualan atau pembelian real estat serta penyediaan jasa real estat lainnya bisa dilakukan atas milik sendiri atau milik orang lain yang dilakukan atas dasar balas jasa kontrak. Kategori ini juga mencakup kegiatan pembangunan gedung, pemeliharaan atau penyewaan bangunan. Real estat adalah property berupa tanah dan bangunan.

13. Jasa Perusahaan

Kategori Jasa Perusahaan merupakan gabungan dari 2 (dua) kategori, yakni kategori M dan kategori N. Kategori M mencakup kegiatan profesional, ilmu pengetahuan dan teknik yang membutuhkan tingkat pelatihan yang tinggi dan menghasilkan ilmu pengetahuan dan ketrampilan khusus yang tersedia untuk pengguna. Kegiatan yang termasuk kategori M antara lain: jasa hukum dan akuntansi, jasa arsitektur dan teknik sipil, penelitian dan pengembangan ilmu pengetahuan, periklanan dan penelitian pasar, serta jasa professional, ilmiah dan teknis lainnya. Kategori N mencakup berbagai kegiatan yang mendukung operasional usaha secara umum. Kegiatan yang termasuk kategori N antara lain: jasa persewaan dan sewa guna usaha tanpa hak opsi, jasa ketenagakerjaan, jasa agen perjalanan, penyelenggaraan tur dan jasa reservasi lainnya, jasa keamanan dan penyelidikan, jasa untuk gedung dan pertamanan, jasa administrasi kantor, serta jasa penunjang kantor dan jasa penunjang usaha lainnya.

14. Administrasi Pemerintahan

Kategori ini mencakup kegiatan yang sifatnya pemerintahan, yang umumnya dilakukan oleh administrasi pemerintahan. Kategori ini juga mencakup perundang-undangan dan penterjemahan hukum yang berkaitan dengan pengadilan dan menurut peraturannya, seperti halnya administrasi program berdasarkan peraturan perundang-undangan, kegiatan legislative, perpajakan, pertahanan Negara, keamanan dan keselamatan Negara, pelayanan imigrasi, hubungan luar negeri dan administrasi program pemerintah, serta jaminan social wajib. Kegiatan yang diklasifikasikan di kategori lain dalam KBLI tidak termasuk pada kategori ini., meskipun dilakukan oleh Badan pemerintahan. Sebagai contoh administrasi sistim sekolah, (peraturan, pemeriksaan, dan kurikulum) termasuk pada kategori ini, tetapi pengajaran itu sendiri masuk kategori Pendidikan (P) dan rumah sakit penjara atau militer diklasifikasikan pada kategori Q.

15. Jasa Pendidikan

Kategori ini mencakup kegiatan pendidikan pada berbagai tingkatan dan untuk berbagai pekerjaan, baik secara lisan atau tertulis seperti halnya dengan berbagai cara komunikasi. Kategori ini juga mencakup pendidikan negeri dan swasta juga mencakup pengajaran yang terutama mengenai kegiatan olahraga, hiburan dan penunjang pendidikan. Pendidikan dapat disediakan dalam ruangan, melalui penyiaran radio dan televisi, internet dan surat menyurat. Tingkat pendidikan dikelompokkan seperti kegiatan pendidikan dasar, pendidikan menengah, pendidikan tinggi dan pendidikan lain, mencakup juga jasa penunjang pendidikan dan pendidikan anak usia dini.

16. Jasa Kesehatan

Kategori ini mencakup kegiatan penyediaan jasa kesehatan dan kegiatan sosial yang cukup luas cakupannya, dimulai dari pelayanan kesehatan yang diberikan oleh tenaga profesional terlatih di rumah sakit dan fasilitas kesehatan lain sampai kegiatan perawatan di rumah yang melibatkan tingkatan kegiatan pelayanan kesehatan sampai kegiatan sosial yang tidak melibatkan tenaga kesehatan profesional. Kegiatan penyediaan jasa kesehatan dan kegiatan sosial

mencakup: Jasa Rumah Sakit; Jasa Klinik; Jasa Rumah Sakit Lainnya; Praktik Dokter; Jasa Pelayanan Kesehatan yang dilakukan oleh Paramedis; Jasa Pelayanan Kesehatan Tradisional; Jasa Pelayanan Penunjang Kesehatan; Jasa Angkutan Khusus Pengangkutan Orang Sakit (Medical Evacuation); Jasa Kesehatan Hewan; Jasa Kegiatan Sosial.

17. Jasa Lainnya

Kategori Jasa Lainnya merupakan gabungan 4 kategori pada KBLI 2009. Kategori ini mempunyai kegiatan yang cukup luas yang meliputi: Kesenian, Hiburan, dan Rekreasi; Jasa Reparasi Komputer Dan Barang Keperluan Pribadi Dan Perlengkapan Rumah Tangga; Jasa Perorangan yang Melayani Rumah Tangga; Kegiatan Yang Menghasilkan Barang dan Jasa Oleh Rumah Tangga Yang Digunakan Sendiri untuk memenuhi kebutuhan; Jasa Swasta Lainnya termasuk Kegiatan Badan Internasional, seperti PBB dan perwakilan PBB, Badan Regional, IMF, OECD, dan lain-lain.

2.4 Manfaat PDRB

Data pendapatan nasional adalah salah satu indikator makro yang dapat menunjukkan kondisi perekonomian nasional setiap tahun^[1]. Manfaat yang dapat diperoleh dari data ini antara lain adalah:

1. PDRB harga berlaku (nominal) menunjukkan kemampuan sumber daya ekonomi yang dihasilkan oleh suatu wilayah. Nilai PDRB yang besar menunjukkan kemampuan sumber daya ekonomi yang besar, begitu juga sebaliknya.
2. PDRB harga konstan (riil) dapat digunakan untuk menunjukkan laju pertumbuhan ekonomi secara keseluruhan atau setiap kategori dari tahun ke tahun.
3. Distribusi PDRB harga berlaku menurut lapangan usaha menunjukkan struktur perekonomian atau peranan setiap kategori ekonomi dalam suatu wilayah. Kategori-kategori ekonomi yang mempunyai peran besar menunjukkan basis perekonomian suatu wilayah.

2.5 Data Mining

Kebutuhan akan dunia bisnis yang ingin memperoleh keuntungan lebih besar dari data yang telah mereka kumpulkan telah mendorong penerapan teknik-teknik analisa data dari berbagai bidang seperti statistik, kecerdasan buatan dsb pada data berskala besar. Ternyata penerapan pada data berskala besar memberikan tantangan yang akhirnya memunculkan metodologi baru yaitu data mining.

Data mining sering disebut sebagai *knowledge discovery in database* (KDD), adalah kegiatan yang meliputi pengeumpulan, pemakaian data historis untuk menemukan keteraturan, pola atau hubungan dalam set data berukuran besar. Data mining juga diartikan sebagai pengekstrakan informasi baru yang diambil dari bongkahan data besar yang membantu dalam pengambilan keputusan dan menentukan kebijakan dimasa yang akan datang(Prasetyo, 2012).

Pekerjaan yang berkaitan dengan data mining dapat dibagi menjadi empat kelompok, yaitu model prediksi (*prediction modelling*), analisis kelompok (*cluster analysis*), analisa asosiasi (*association analysis*), dan deteksi anomaly (*anomaly detection*).

1. Model prediksi

Model prediksi berkaitan dengan pembuatan sebuah model yang dapat melakukan pemetaan dari setiap himpunan variabel ke setiap targetnya, kemudian menggunakan model tersebut untuk memberikan nilai target pada himpunan baru yang didapat. Ada dua jenis model prediksi, yaitu klasifikasi dan regresi. Klasifikasi digunakan untuk variabel target diskret, sedangkan regresi untuk variabel target kontinu.

2. Analisis kelompok

Analisis kelompok melakukan pengelompokkan data-data ke dalam sejumlah kelompok (*cluster*) berdasarkan kesamaan karakteristik masing-masing data pada kelompok-kelompok yang ada. Data-data yang masuk dalam batas kesamaan dengan kelompoknya akan bergabung dalam kelompok tersebut, dan

akan terpisah dalam kelompok yang berbeda jika keluar dari batas kesamaan dengan kelompok tersebut.

3. Analisis asosiasi

Analisis asosiasi digunakan untuk menemukan pola yang menggambarkan kekuatan hubungan fitur dalam data. Pola yang ditemukan biasanya merepresentasikan bentuk aturan implikasi atau subset fitur. Tujuannya adalah untuk menemukan pola yang menarik dengan cara yang efisien.

4. Deteksi anomali

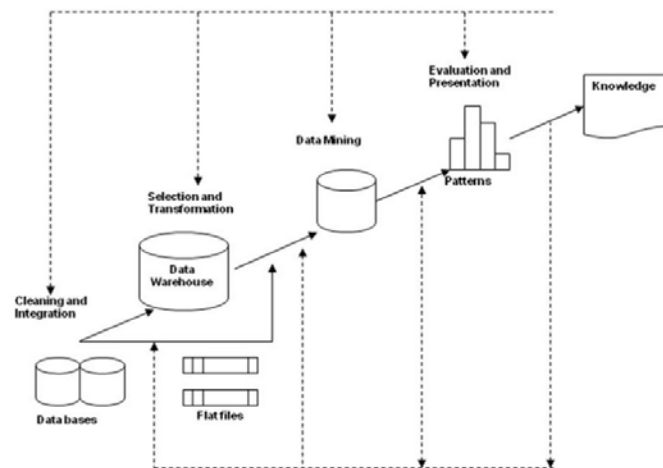
Deteksi anomaly berkaitan dengan pengamatan sebuah data dari sejumlah data yang secara signifikan mempunyai karakteristik yang berbeda dari sisa data yang lain. Data-data yang karakteristiknya menyimpang (berbeda) dari data yang lain disebut *outlier*.

Teknik-teknik yang digunakan dalam data mining dibagi 2 (Santosa, 2007) yaitu :

1. *Unsupervised learning* : metode tanpa adanya latihan (*training*), sehingga tidak diketahui keluarannya (*outputnya*). Contoh dalam metode ini adalah *K-Means* dan *self organizing maps (SOM)*.
2. *Supervised learning* : metode dengan adanya latihan (*training*), sehingga dapat diketahui keluarannya (*outputnya*). Contoh dalam metode ini : analisis diskriminan (LDA), regresi dan *support vector machine (SVM)*.

2.6 Tahap Data Mining

Data tidak serta merta dapat langsung diolah menggunakan teknik data mining. Data tersebut harus melalui proses penyiapan terlebih dahulu agar hasil yang diperoleh dapat lebih maksimal, dan waktu komputasi juga lebih maksimal. Oleh karena itu diperlukan suatu rangkaian proses dalam data mining. Gambar 2.1 memperlihatkan tahap dalam data mining.



Gambar 2.1 Tahap Pada Data Mining (Oded and Lior, 2011)

1. Pembersihan Data (*Data Cleaning*)

Pembersihan data merupakan proses menghilangkan noise yang tidak konsisten atau data tidak relevan. Pada umumnya data yang diperoleh, baik dari database suatu perusahaan maupun hasil eksperimen memiliki isian-isian yang tidak sempurna seperti data yang hilang, data yang tidak valid atau juga hanya sekedar salah ketik. Selain itu, ada juga atribut-atribut data yang tidak relevan itu lebih baik dibuang. Pembersihan data juga akan mempengaruhi performansi dari teknik data mining karena data yang ditangani akan berkurang jumlah kompleksitasnya.

2. Integrasi Data (*Data Integration*)

Integrasi merupakan penggabungan data dari berbagai sumber dan database ke dalam satu database baru. Tidak jarang data yang diperlukan untuk data mining tidak hanya berasal dari satu database tetapi juga bisa berasal dari database lain.

3. Seleksi Data (*Data Selection*)

Data yang ada dalam database tidak semuanya bisa dipakai, oleh karena itu diperlukan proses seleksi hanya data untuk analisis yang akan diambil dan digunakan.

4. Transformasi Data (*Data Transformation*)

Data diubah dan digabung ke dalam format yang sesuai untuk proses dalam data mining. Beberapa metode data mining membutuhkan format data yang khusus sebelum bisa diaplikasikan.

5. Proses Mining

Proses mining merupakan proses utama saat metode diterapkan untuk menemukan informasi baru dan pengetahuan. Mencoba data mining lain yang sesuai, atau menerima hasil ini sebagai suatu hasil diluar dugaan yang mungkin bermanfaat.

6. Presentasi Pengetahuan (*Knowledge Presentation*)

Presentasi merupakan visualisasi dan penyajian pengetahuan hasil mengenai metode yang digunakan untuk memperoleh informasi yang berharga.

7. Evaluasi Pola (*Pattern Evaluation*)

Untuk mengidentifikasi pola-pola yang menarik kedalam *knowledge based* yang ditemukan. Dalam tahap ini hasil dari teknik data mining berupa pola-pola yang khas maupun model prediksi dievaluasi untuk menilai apakah hipotesa yang ada memang tercapai. Bila ternyata hasil yang diperoleh tidak sesuai hipotesa ada beberapa alternative yang dapat diambil seperti menjadikannya umpan balik untuk memperbaiki proses data mining, pengetahuan yang diperoleh pengguna. Tahap akhir dari proses data mining adalah bagaimana menformulasikan keputusan atau aksi dari hasil analisis yang didapat.

2.7 Normalisasi Data PDRB

Suatu data sering disajikan pada fitur dengan nilai yang terletak dalam jangkauan nilai berbeda. Akibatnya, fitur dengan nilai atau jangkauan yang besar mempunyai pengaruh yang lebih besar dalam fungsi biaya daripada fitur dengan nilai kecil atau jangkauan kecil. Untuk mengatasi masalah ini bisa digunakan teknik normalisasi fitur sehingga semua fitur akan berada dalam jangkauan yang sama. Normalisasi ini digunakan pada data PDRB menurut lapangan usaha. Salah

satu cara yang dapat digunakan adalah normalisasi linear (Prasetyo, 2014). Masing-masing fitur dihitung nilai mean Persamaan (2.1) dan varian Persamaan (2.2). Maka untuk N data yang ada pada fitur ke- k didapat :

$$\bar{x}_z = \frac{1}{N} \sum_{i=1}^N x_{yz} = 12, \dots r \quad (2.1)$$

$$\sigma_z^2 = \frac{1}{N-1} \sum_{i=1}^N (x_{yz} - \bar{x}_z)^2 \quad (2.2)$$

Data hasil normalisasi dihitung menggunakan persamaan (2.3) :

$$\hat{x}_{yz} = \frac{x_{yz} - \bar{x}_z}{\sigma_z} \quad (2.3)$$

Hasil normalisasi dengan cara tersebut didapatkan fitur yang mempunyai sifat *zero-mean* dan *unit-variance*. Teknik linear yang lain adalah dengan menskalakan jangkauan setiap fitur dalam jangkauan $[0,1]$ atau $[-1,1]$. Untuk menskalakan dalam jangkauan $[0,1]$ dapat digunakan Persamaan (2.4) :

$$\hat{x}_{yz} = \frac{x_{yz} - m_{\min}(x_z)}{m_{\max}(x_z) - m_{\min}(x_z)} \quad (2.4)$$

Sementara untuk menskalakan dalam jangkauan $[-1,1]$ digunakan Persamaan (2.5)


$$\hat{x}_{yz} = \frac{2x_{yz} - (m_{\max}(x_z) + m_{\min}(x_z))}{m_{\max}(x_z) - m_{\min}(x_z)} \quad (2.5)$$

2.8 Analisis Klaster

Analisa kelompok (*cluster*) merupakan suatu analisa statistik yang bertujuan untuk memisahkan obyek ke dalam beberapa kelompok yang mempunyai sifat berbeda antara kelompok yang satu dengan kelompok yang lain. Dalam analisa klaster antar anggota dalam satu kelompok bersifat homogen. Tujuan utama dari analisa klaster adalah untuk menggabungkan objek-objek yang mempunyai kesamaan ke dalam satu kelompok. Dalam melakukan analisa klaster dibutuhkan sebuah rancangan mulai dari bagaimana kita mengukur tingkat kesamaan anggota dalam klaster, kemudian dengan cara apa kita membentuk klaster, dan seberapa banyak klaster yang akan kita bentuk_[9]. Analisa klaster melakukan pemrosesan data secara alami dengan algoritma yang berjalan sendiri sehingga didapatkan kelompok-kelompok yang terbentuk secara alami pula. Pada

dasarnya, analisa klaster adalah proses penggalian informasi baru yang sebelumnya tidak ada sehingga seolah-olah menjadi pertanyaan mengapa harus dilakukan evaluasi. Padahal, komposisi klaster yang didapat adalah informasi baru yang didapatkan sehingga seolah-olah evaluasi klaster adalah pekerjaan tambahan yang seharusnya tidak perlu dilakukan(Irhamni, dkk, 2012).

Susunan klaster yang berbeda yang didapatkan dari set data yang sama tentu memberikan nilai evaluasi yang berbeda pula. Basis metode yang berbeda juga memberikan cara evaluasi yang berbeda. Ilustrasi data klastering ditunjukkan pada Gambar 2.2.



Gambar 2.2 Ilustrasi Klastering (Prasetyo, 2012)

2.9 Algoritma *K-Means*

Algoritma *K-Means* merupakan algoritma yang digunakan untuk mengelompokkan iterative, algoritma ini melakukan partisi set data ke dalam sejumlah K klaster yang sudah ditetapkan dari awal. Dalam penelitian ini algoritma *K-Means* digunakan untuk mengelompokkan data PDRB sehingga klaster yang memiliki karakteristik sama dikelompokkan ke dalam satu klaster dan yang memiliki karakteristik berbeda dikelompokkan ke dalam klaster lain. Dibawah ini adalah langkah-langkah algoritma *K-Means*(Prasetyo, 2014).

Langkah algoritma *K-Means*:

1. Tentukan jumlah klaster
2. Menentukan *centroid* yang awal digunakan
3. Menghitung jarak setiap data ke masing-masing *centroid* menggunakan *Euclidean* untuk mendapatkan jarak terdekat data dengan *centroid* menggunakan Persamaan (2.6):

$$d_{(j)} = \sqrt{\sum_{k=1}^p (x_k - x_{jk})^2}$$

(2.6)

Dimana:

$d_{(j)}$: Jarak data ke *centroid*

x_k : Data ke i pada indikator ke k

c_{jk} : Centroid ke j pada indikator ke k

4. Menentukan centroid baru dengan menghitung rata-rata dari data yang ada pada *centroid* yang sama menggunakan persamaan (2.7):

$$c_j = \frac{1}{N_k} \sum_{l=1}^{N_k} x_{jl} \quad (2.7)$$

Dimana:

x_{jl} : Total nilai pada data ke j

c_j : Centroid baru

5. Ulangi langkah 3 dan 4 hingga kondisi konvergen tercapai, yaitu perubahan fungsi objektif sudah dibawah ambang batas yang diinginkan, atau tidak ada data yang berpindah klaster.

Contoh perhitungan manual data menggunakan metode *K-Means*:

Diketahui data:

Data	x	y	z
A	1	2	3
B	1	1	2
C	2	3	1
D	2	2	1
E	3	3	3

Tentukan jumlah klaster $K=3$

Tentukan centroid awal secara random:

C1	1	2	3
C2	1	1	2
C3	2	2	1

Iterasi ke 1

1. Hitung jarak data ke *centroid* menggunakan persamaan *Euclidean Distance*:

$$C1 = \sqrt{(1-1)^2 + (2-2)^2 + (3-3)^2} = \sqrt{0 + 0 + 0} = 0$$

$$C2 = \sqrt{(1-1)^2 + (2-1)^2 + (3-2)^2} = \sqrt{0 + 1 + 1} = 1.414$$

$$C3 = \sqrt{(1-2)^2 + (2-2)^2 + (3-1)^2} = \sqrt{1 + 0 + 4} = 2.236$$

Perhitungan ini dilakukan terus menerus terhadap data ke 2 hingga terakhir

Data	C1	C2	C3	Terdekat	Diikuti
A	0	1.414	2.236	0	C1
B	1.414	0	1.732	0	C2
C	2.449	2.449	1	1	C3
D	2.236	1.732	0	0	C3
E	2.236	3	2.449	2.236	C1

2. Hitung *centroid* yang baru untuk setiap kluster berdasarkan data yang tergabung kedalam kluster yang sama.

Untuk kluster 1

Data	x	y	z
A	1	2	3
E	3	3	3
Jumlah	4	5	6
$N k = 2$			
Rata2	2	2.5	3

Untuk kluster 2

Data	x	y	z
B	1	1	2
Jumlah	1	1	2
$N k = 1$			
Rata2	1	1	2

Untuk kluster 3

Data	x	y	z
C	2	3	1
D	2	2	1
Jumlah	4	5	2
$N k = 2$			
Rata2	2	2.5	1

Centroid baru

C1	2	2.5	3
C2	1	1	2
C3	2	2.5	1

Iterasi ke 2

1. Hitung jarak data ke *centroid* yang baru

$$C1 = \sqrt{(1-2)^2 + (2-2.5)^2 + (3-3)^2} = \sqrt{1 + 0.25 + 0} = 1.118$$

$$C2 = \sqrt{(1-1)^2 + (2-1)^2 + (3-2)^2} = \sqrt{0 + 1 + 1} = 1.414$$

$$C3 = \sqrt{(1-2)^2 + (2-2.5)^2 + (3-1)^2} = \sqrt{1 + 0.25 + 4} = 2.291$$

Perhitungan ini dilakukan terus menerus terhadap data ke 2 hingga terakhir

Data	C1	C2	C3	Terdekat	Diikuti
A	1.118	1.414	2.291	1.118	C1
B	2.062	0	2.062	0	C2
C	2.062	2.449	0.5	0.5	C3
D	2.062	1.732	0.5	0.5	C3
E	1.118	3	2.291	1.118	C1

2. Hitung *centroid* yang baru untuk setiap kluster berdasarkan data yang tergabung kedalam kluster yang sama.

Untuk kluster 1

Data	x	y	z
A	1	2	3
E	3	3	3
Jumlah	4	5	6
$N_k = 2$			
Rata2	2	2.5	3

Untuk kluster 2

Data	x	y	z
B	1	1	2
Jumlah	1	1	2
$N_k = 1$			
Rata2	1	1	2

Untuk kluster 3

Data	x	y	z
C	2	3	1
D	2	2	1
Jumlah	4	5	2
$N k = 2$			
Rata2	2	2.5	1

Centroid baru

C1	2	2.5	3
C2	1	1	2
C3	2	2.5	1

3. Ulangi terus perhitungan diatas hingga data tidak berpindah lagi dari kluster.
4. Anggota hasil akhir proses kluster diatas

Data	x	y	z	C
A	1	2	3	C1
B	1	1	2	C2
C	2	3	1	C3
D	2	2	1	C3
E	3	3	3	C1

2.10 Self-Organizing Maps (SOM)

Jaringan *Self Organizing Maps (SOM)* sering disebut juga *topology preversing maps* pertama kali diperkenalkan oleh Tuevo Kohonen dari University of Helsinki pada tahun 1981 (Kasabov, 1998), dan (Kristanto, 2004). Jaringan *SOM* merupakan salah satu jaringan yang banyak dipakai, antara lain untuk membagi pola masukan kedalam beberapa kluster (Siang, 2009).


Dalam *SOM* masukan berupa vektor yang terdiri dari n komponen (tuple) yang akan dikelompokkan dalam maksimum m buah kelompok (disebut vektor contoh). Keluaran jaringan adalah kelompok yang paling dekat/ mirip dengan masukan yang diberikan. Ada beberapa ukuran kedekatan yang dapat dipakai. Ukuran yang sering dipakai adalah jarak Euclidean yang paling minimum (Siang, 2009).

Vektor bobot untuk sebuah unit kluster menyediakan sebuah contoh dari pola input yang dikumpulkan dalam kluster. Selama proses self organizing, unit

klaster yang mempunyai bobot dicocokkan dengan pola input yang terdekat dan dipilih sebagai pemenang. Unit pemenang dan unit tetangganya (dalam hal ini adalah topologi dari unit klaster) memperbaiki bobot mereka masing-masing (Kristanto, 2004).

2.10.1 Arsitektur *Self-Organizing Maps (SOM)*

SOM merupakan generalisasi dari jaringan kompetitif, dan merupakan jaringan tanpa supervise (Siang, 2009). *SOM* disusun oleh sebuah lapisan unit input yang dihubungkan seluruhnya ke lapisan unit output, yang kemudian unit-unit diatur di dalam topologi khusus seperti struktur jaringan (Jain & Martin, 1998). Secara umum arsitektur jaringan *SOM* dapat dilihat pada Gambar 2.3 berikut.



Gambar 2.3 Arsitektur *SOM* (Kristanto, 2004)

2.10.2 Algoritma *Self-Organizing Maps (SOM)*

Pada penelitian ini algoritma *SOM* digunakan untuk mengelompokkan data PDRB menurut lapangan usaha. Pada prinsipnya algoritma *SOM* mempunyai 2 proses perhitungan matematika, yaitu pada proses pencarian nilai bobot yang sesuai dengan nilai masukan dan perubahan nilai bobot yang telah ditemukan dengan jarak terdekat. Perhitungan perubahan nilai bobot, untuk bobot tetangga tidak dihitung atau diberi nilai 0. Pemberian nilai ini dimaksudkan agar tiap bobot diarahkan ke nilai masukan sehingga nilai bobot akan mendekati nilai masukan.

Algoritma klaster dengan *SOM*:

1. Inisialisasi bobot W_{ij} . Tentukan parameter laju pebelajaran. Tentukan maksimal iterasi pelatihan

2. Selama jumlah maksimal iterasi belum tercapai, lakukan langkah 3 - 7
3. Untuk setiap data masukan X , lakukan langkah 4 - 6
4. Untuk setiap neuron j , hitung $d_j = \sum_i (w_{ij} - x_i)^2$, $i=1, \dots, N$, N adalah dimensi data (N)
5. Menentukan indeks dari sejumlah neuron, yaitu d_j , yang mempunyai nilai terkecil
6. Perbarui bobot hitung $w_{ij}^{baru} = w_{ij}^{lama} + \alpha(x_i - w_{ij}^{lama})$
7. Perbarui laju pembelajaran
8. Uji kondisi penghentian

Penyelesaian permasalahan klastering data menggunakan Jaringan *SOM* dipengaruhi oleh parameter-parameter seperti jumlah kelompok yang akan dibentuk, learning rate, maksimum iterasi (*epochs*) sehingga jika proses dilakukan beberapa kali dengan data masukan yang sama, akan berpengaruh pada pengelompokan data yang dihasilkan. Hal ini disebabkan pada Algoritma *SOM* untuk pengelompokan data terdapat pemilihan data secara acak (randomisasi).

2.11 Validasi Klaster

Validasi pada metode *unsupervised* mengukur kebagusan struktur klaster tanpa membutuhkan informasi eksternal (yang biasa dipakai metode klasifikasi). Metrik *unsupervised* pada validitas klaster sering dibagi menjadi dua macam, yaitu kohesi dan separasi. Ukuran kohesi/kekompakan/kerapatan klaster menentukan seberapa dekat hubungan data dalam klaster, sedangkan ukuran separasi klaster menentukan seberapa berbeda atau bagus keterpisahan sebuah klaster dari klaster yang lain. Metrik *unsupervised* sering disebut juga *indeks internal* karena hanya menggunakan informasi apa adanya yang ada dalam set data (Irhamni, dkk, 2012).

2.11.1 Validasi Internal

Banyak sekali metrik yang digunakan untuk mengukur validitas klaster pada metode pengelompokan berbasis partisi didasarkan pada nilai kohesi dan separasi. Kohesi dalam pengelompokan berbasis partisi didefinisikan sebagai

jumlah dari kedekatan data terhadap centroid dari klaster yang diikutinya. Sedangkan separasi diantara dua klaster dapat diukur dengan kedekatan dua centroid klaster.

2.11.1.1 *Davies-Bouldin Index (DBI)*

Metrik *Davies-Bouldin Index (DBI)* diperkenalkan oleh David L. Davies dan Donald W. Bouldin (1979) yang digunakan untuk mengevaluasi klaster. Validitas internal yang dilakukannya adalah seberapa baik klastering sudah dilakukan dengan menghitung kuantitas dan fitur turunan dari set data (Prasetyo, 2014).

Sum of square within cluster (SSW) sebagai metrik kohesi dalam sebuah klaster ke- i diformulasikan pada Persamaan (2.8):

$$SSW_i = \frac{1}{m_i} \sum_{j=1}^{m_i} d(x_j, c_i) \quad (2.8)$$

Sementara metrik untuk separasi antara dua klaster, digunakan formula *sum of square between cluster (SSB)* dengan mengukur jarak antara centroid c_i dan c_j diformulasikan pada persamaan (2.9).

$$SSB_{ij} = d(c_i, c_j) \quad (2.9)$$

R_{ij} mengukur seberapa baik nilai perbandingan antara cluster ke- i dan klaster ke- j . nilainya didapatkan dari komponen kohesi dan separasi. Klaster yang baik adalah yang mempunyai kohesi sekecil mungkin dan separasi sebesar mungkin. R_{ij} diformulasikan pada persamaan (2.10).

$$R_{ij} = \frac{SSW_i + SSW_j}{SSB_{ij}} \quad (2.10)$$

Nilai *Davies-Bouldin Index (DBI)* diformulasikan pada persamaan (2.11).

$$DBI = \frac{1}{K} \sum_{i=1}^K \max_{i \neq j} (R_{ij}) \quad (2.11)$$

Dimana K adalah jumlah cluster yang digunakan. Dari syarat-syarat perhitungan yang didefinisikan di atas, ditentukan bahwa semakin kecil nilai SSW maka hasil klastering yang didapat juga lebih baik. DBI menginginkan nilai sekecil mungkin (non-negatif ≥ 0) untuk menilai baiknya klaster yang didapatkan. Indeks tersebut didapat dari rata-rata semua indeks klaster, dan nilai yang didapat bisa digunakan sebagai pendukung keputusan untuk menilai jumlah klaster yang paling cocok digunakan.

Contoh perhitungan *Davies-Bouldin Index (DBI)* untuk klaster =3:

Diketahui anggota klaster

Data	x	y	z	C
A	1	2	3	C3
B	1	1	2	C2
C	2	3	1	C1
D	2	2	1	C1
E	3	3	3	C3

Centroid yang didapat

Centroid	x	y	z
C1	2	2.5	1
C2	1	1	2
C3	2	2.5	3

Untuk mendapatkan nilai *Sum of square within cluster (SSW)* jarak data dalam klaster:

$$d(x_3 c_1) = \sqrt{(2 - 2)^2 + (3 - 2.5)^2 + (1 - 1)^2} = 0.5$$

$$d(x_4 c_1) = \sqrt{(2 - 2)^2 + (2 - 2.5)^2 + (1 - 1)^2} = 0.5$$

$$SSW_1 = \frac{1}{2}(0.5 + 0.5) = 0.5$$

Perhitungan ini dilakukan juga terhadap klaster 2 dan 3, hasil perhitungan

Data	x	y	z	Jarak	SSW
C	2	3	1	0.5	0.5
D	2	2	1	0.5	
B	1	1	2	0	0
A	1	2	3	1.1180	1.1180
E	3	3	3	1.1180	

Untuk mencari nilai *sum of square between cluster (SSB)* jarak antar klaster:

$$SSB_{12} = d(c_1 c_2) = \sqrt{(2 - 1)^2 + (25 - 1)^2 + (1 - 2)^2} = 20615$$

$$SSB_{13} = d(c_1 c_3) = \sqrt{(2 - 2)^2 + (25 - 25)^2 + (1 - 3)^2} = 2$$

$$SSB_{23} = d(c_2 c_3) = \sqrt{(1 - 2)^2 + (1 - 25)^2 + (2 - 3)^2} = 20615$$

Untuk mencari nilai *R* (rasio):

$$R_{12} = \frac{05 + 0}{20615} = 02425$$

$$R_{13} = \frac{05 + 11180}{2} = 08090$$

$$R_{23} = \frac{0 + 11180}{20615} = 05423$$

Selanjutnya untuk mencari nilai *DBI*:

		Data ke- <i>i</i>			R Max	<i>DBI</i>
	R	1	2	3		
Data ke- <i>i</i>	1	0	0.2425	0.8090	0.8090	0.7201
	2	0.2425	0	0.5423	0.5423	
	3	0.8090	0.5423	0	0.8090	

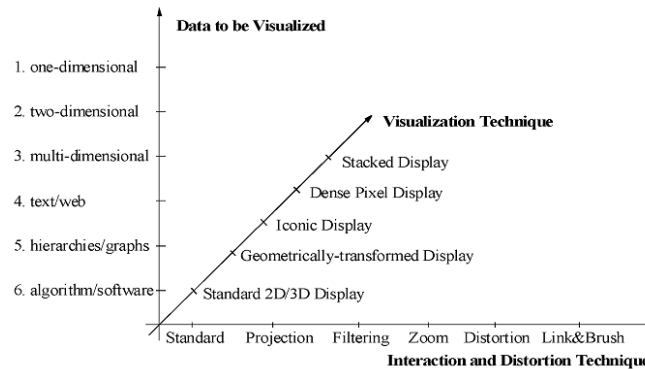
2.12 Visualisasi Informasi

Visualisasi Informasi adalah suatu metode penggunaan komputer untuk menemukan metode terbaik dalam menampilkan data untuk mengingat informasi dengan cara alami manusia serta memberikan cara untuk melihat data yang sulit dilihat dengan pemikiran sehingga peneliti bisa mengamati simulasi dan komputasi, juga memperkaya proses penemuan ilmiah dan mengembangkan pemahaman yang lebih dalam dan tak terduga.

2.12.1 Teknik Visualisasi

Ada beberapa teknik visualisasi yang biasanya dapat digunakan untuk memvisualisasikan data, selain teknik 2D/3D, grafik batang, grafik garis dan lain-lain. Ada juga sejumlah teknik visualisasi yang lebih canggih. Sesuai dengan prinsip-prinsip dasar visualisasi dapat dikombinasikan untuk menerapkan


visualisasi tertentu(Daniel, 2002). Gambar 2.4 menunjukkan klasifikasi teknik visualisasi informasi.




Gambar 2.4 Klasifikasi Teknik Visualisasi Informasi (Daniel, 2002)

Salah satu teknik visualisasi adalah teknik proyeksi geometri. Teknik proyeksi geometri digunakan untuk memperoleh proyeksi yang menarik atas sekumpulan data multidimensi. Klas dari teknik proyeksi geometri mencakup teknik pengujian statistik seperti komponen utama analisis, analisis factor dan penskalaan multidimensional, yang merupakan bagian dari istilah *projection pursuit* [Hurber 1985] [Friedman dan Turkey 1974].

Teknik proyeksi geometri yang lain adalah teknik visualisasi koordinat paralel [Inselberg 1985] [Inselberg dan Dimsdale 1990]. Teknik koordinat paralel, memetakan ruang berdimensi k ke tampilan dua dimensi dengan menggunakan k sumbu yang berjarak sama dan saling paralel dengan sumbu tampilan. Sejak kemunculan konsep koordinat paralel sangat banyak dimanfaatkan untuk visualisasi khususnya data multidimensi dan analisis data.



Gambar 2.5 Teknik koordinat paralel (Daniel, 2002)



Gambar 2.6 Teknik visualisasi data berdimensi tiga (Daniel, 2002)

[Halaman ini sengaja dikosongkan]

BAB 3

METODOLOGI PENELITIAN

Bab ini menjelaskan tahapan dalam penelitian untuk menghasilkan kluster Kabupten/Kota menurut kesamaan karakteristik berdasarkan indikator pembentuk PDRB menurut lapangan usaha.

3.1 Alur Penelitian

Berikut adalah tahapan yang digunakan dalam penelitian ini. dapat dilihat pada Gambar 3.1.



Gambar 3.1 Alur Metodologi Penelitian

3.2 Pengambilan dan Mempersiapkan Data PDRB

Data Produk Domestik Regional Bruto (PDRB) menurut lapangan usaha adalah data sekunder yang diperoleh dari Badan Pusat Statistik (BPS). Semakin besar angka PDRB maka perekonomian di daerah itu tinggi begitu juga sebaliknya. Data Produk Domestik Regional Bruto (PDRB) dibentuk dari 17 indikator lapangan usaha.

3.3 Persiapan Data

Data PDRB menurut lapangan usaha diperoleh dari Badan Pusat Statistik (BPS). Data yang masih berupa hardcopy akan dijadikan satu dengan data lain yang sudah format softcopy. Setelah itu data PDRB diubah kedalam format *.csv dan *.txt.

3.4 Normalisasi Data

Proses normalisasi dilakukan untuk penyesuaian data. Teknik yang digunakan adalah teknik linier dengan menskalakan jangkauan minimal 0 dan maksimal 1. Normalisasi data dilakukan pada setiap indikator PDRB yang memiliki nilai bervariasi. Data PDRB sebelum normalisasi dapat dilihat pada Tabel 3.1.

Tabel 3.1 Data PDRB Sebelum Normalisasi (Dalam Milyar Rupiah)

No	Kabupaten/Kota	PRT	PTM	IP	...	JL
1	KabKepulauanSeribu	273.4	4540.9	142.9	...	53
2	KotaJakSel	302.7	0	5968.1	...	20867.1
3	KotaJakTim	313.8	0	92230.3	...	7874.6
4	KotaJakPus	37.9	0	3829.9	...	13875.8
5	KotaJakBar	284.1	0	18817.4	...	8970.8
6	KotaJakUta	481.8	0	118226.2	...	9557.6
7	KabBogor	8459.7	4546.3	83547.5	...	2355.8
8	KabSukabumi	9567.2	3310.3	6113.8	...	692.1
9	KabBandung	6133.3	1784.3	39546.2	...	1507
10	KabGarut	14504.5	930.3	2723.9	...	1017
11	KabKuningan	3703.7	285.3	355.2	...	437.8
12	KabCirebon	5636.7	529.1	7053	...	977.4
13	KabMajalengka	5224.3	455.3	2660.5	...	475.1
14	KabSumedang	4849.9	25	4217.7	...	359.2
15	KabIndramayu	10766.1	10757	29819.9	...	221.5
16	KabKarawang	6446.1	4582.2	110088.4	...	1092.4

17	KabBekasi	3227.7	3422.3	177640.3	...	1187.1
18	KabBandungBrt	4476	416.1	11996.3	...	303
19	KabBogor	241.5	0	5393	...	816.6
20	KotaSukabumi	321.9	0	441.3	...	220.7
21	KotaBandung	236.5	0	37095.5	...	5815.7
22	KotaCirebon	53.2	0	1607.9	...	314.5
23	KotaBekasi	411.8	0	23113.8	...	1639.5
24	KotaDepok	634.2	0	15080.2	...	1388.8
25	KotaTasikMalaya	795.7	1.5	2030.5	...	329
...
...
...
444	KabKarimun	1427.8	1005.5	1230.3	...	130.1
445	KabNatuna	1632.8	12579.5	115.3	...	9.9
446	KabLingga	674.1	269.2	20	...	20.4
447	KabBatam	1127.4	84.1	60914.5	...	416.7
448	KotaTanjPinang	125.1	50.9	1000.7	...	167.9

Sumber: Badan Pusat Statistik , 2015

Sebelum dilakukan proses normalisasi data, dicari terlebih dahulu nilai minimum dan maksimum masing-masing indikator PDRB. Nilai minimum dan maksimum dapat dilihat pada Tabel 3.2.

Tabel 3.2 Nilai Minimum dan Maksimum Masing-Masing Indikator PDRB

Indikator	Minimum	Maksimum
PRT	30.4	24380.6
PTM	0	129876.4
IP	0.2	177640.3
PLG	0	5281.2
PAP	0	601.3
KONS	21.7	54505.4
PER	1.4	99966.8
TRA	2.2	18927.7
PAM	0	54062.9
IK	0	41891.6
JK	0	96495.9
RE	1	31772.7
JP	0	38788.5
AP	20.5	41588.9
JPEN	2.5	24270.4
JKES	1.1	7554.9
JL	0.04	20867.1

Setelah itu untuk melakukan normalisasi data digunakan menggunakan Persamaan (3.1):

$$\hat{x}_{yz} = \frac{x_{yz} - \min(x_z)}{\max(x_z) - \min(x_z)} \quad (3.1)$$

Dimana :

\hat{x}_{yz} : Hasil Normalisasi data ke y

x_{yz} : Nilai data ke y

$\min(x_z)$: Nilai minimum

$\max(x_z)$: Nilai maksimum

Contoh perhitungan normalisasi pada indikator pertanian Kabupaten Kepulauan Seribu dan Kota Jakarta Selatan:

$$\frac{273.4 - 30.4}{24380.6 - 30.4} = \frac{243}{24350.2} = 0.0099$$

$$\frac{302.7 - 30.4}{24380.6 - 30.4} = \frac{272.3}{24350.2} = 0.0112$$

Perhitungan ini dilakukan terus menerus terhadap data pertama hingga data terakhir pada masing-masing indikator hingga selesai. Hasil perhitungan normalisasi dapat dilihat pada Tabel 3.3.

Tabel 3.3 Data PDRB Setelah Normalisasi

No	Kabupaten/Kota	PRT	PTM	IP	...	JL
1	KabKepulauanSeribu	0.0100	0.0350	0.0008	...	0.0025
2	KotaJakSel	0.0112	0.0000	0.0336	...	1.0000
3	KotaJakTim	0.0116	0.0000	0.5192	...	0.3774
4	KotaJakPus	0.0003	0.0000	0.0216	...	0.6650
5	KotaJakBar	0.0104	0.0000	0.1059	...	0.4299
6	KotaJakUta	0.0185	0.0000	0.6655	...	0.4580
7	KabBogor	0.3462	0.0350	0.4703	...	0.1129
8	KabSukabumi	0.3917	0.0255	0.0344	...	0.0332
9	KabBandung	0.2506	0.0137	0.2226	...	0.0722
10	KabGarut	0.5944	0.0072	0.0153	...	0.0487
11	KabKuningan	0.1509	0.0022	0.0020	...	0.0210
12	KabCirebon	0.2302	0.0041	0.0397	...	0.0468
13	KabMajalengka	0.2133	0.0035	0.0150	...	0.0228
14	KabSumedang	0.1979	0.0002	0.0237	...	0.0172

15	KabIndramayu	0.4409	0.0828	0.1679	...	0.0106
16	KabKarawang	0.2635	0.0353	0.6197	...	0.0523
17	KabBekasi	0.1313	0.0264	1.0000	...	0.0569
18	KabBandungBrt	0.1826	0.0032	0.0675	...	0.0145
19	KabBogor	0.0087	0.0000	0.0304	...	0.0391
20	KotaSukabumi	0.0120	0.0000	0.0025	...	0.0106
21	KotaBandung	0.0085	0.0000	0.2088	...	0.2787
22	KotaCirebon	0.0009	0.0000	0.0091	...	0.0151
23	KotaBekasi	0.0157	0.0000	0.1301	...	0.0786
24	KotaDepok	0.0248	0.0000	0.0849	...	0.0666
25	KotaTasikMalaya	0.0314	0.0000	0.0114	...	0.0158
...
...
...
444	KabKarimun	0.0574	0.0077	0.0069	...	0.0062
445	KabNatuna	0.0658	0.0969	0.0006	...	0.0005
446	KabLingga	0.0264	0.0021	0.0001	...	0.0010
447	KabBatam	0.0451	0.0006	0.3429	...	0.0200
448	KotaTanjPinang	0.0039	0.0004	0.0056	...	0.0080

Nilai rata-rata pada masing-masing indikator digunakan sebagai pembandingan untuk menentukan kategori rendah dan tinggi. Setelah kluster terbaik ditentukan diambil nilai rata-rata dari masing-masing indikator seluruh data (\bar{X}). Selanjutnya diambil rata-rata indikator dari masing-masing kluster (\bar{X}_c). Kategori ditentukan berdasarkan syarat, jika ($\bar{X}_c > \bar{X}$) maka disebut kategori tinggi, sedangkan jika ($\bar{X}_c < \bar{X}$) maka disebut kategori rendah. Nilai rata-rata Indikator PDRB dapat dilihat pad Tabel 3.4.

Tabel 3.4 Nilai Rata-Rata Indikator PDRB

No	Indikator	Rata2 Per Indikator (\bar{X})
1	PRT	0.1123
2	PTM	0.0160
3	IP	0.0280
4	PLG	0.0159
5	PAP	0.0318
6	KONS	0.0411
7	PER	0.0299
8	TRA	0.0441
9	PAM	0.0134
10	IK	0.0201
11	JK	0.0089
12	RE	0.0202

13	JP	0.0094
14	AP	0.0199
15	JPEN	0.0295
16	JKES	0.0303
17	JL	0.0167

3.5 Klastering Kabupaten/Kota Menggunakan *K-Means*

Selanjutnya data PDRB menurut lapangan usaha masuk ke dalam proses klastering. Uji coba dilakukan dengan mengelompokan data mulai dari 3 sampai 10 klaster.

Langkah algoritma *K-Means*:

1. Tentukan jumlah klaster
2. Tentukan *centroid* yang awal secara random.
3. Hitung jarak setiap data ke masing-masing *centroid* untuk mendapatkan jarak terdekat data dengan *centroid* menggunakan Persamaan *Euclidean Distance* (3.2):

$$d_{(i,j)} = \sqrt{\sum_{k=1}^p (x_{ik} - c_{jk})^2}$$

(3.2)

Dimana:

$d_{(i,j)}$: Jarak data ke *centroid*

x_{ik} : Data ke i pada indikator ke k

c_{jk} : Centroid ke j pada indikator ke k

4. Tentukan *centroid* baru dengan menghitung rata-rata dari data yang ada pada klaster yang sama menggunakan Persamaan (3.3):

$$c_j = \frac{1}{N_k} \sum_{l=1}^{N_k} x_{jl} \quad (3.3)$$

5. Ulangi langkah 3 dan 4 hingga kondisi konvergen tercapai, yaitu atau tidak ada data yang berpindah klaster.

3.6 Klastering Kabupaten/Kota Menggunakan SOM

Pada klastering menggunakan SOM, Uji coba dilakukan dengan mengelompokkan data mulai dari 3 sampai 10 cluster.

Algoritma klaster dengan SOM:

1. Inisialisasi bobot W_{ij} . Tentukan parameter laju pebelajaran. Tentukan maksimal iterasi pelatihan
2. Selama jumlah maksimal iterasi belum tercapai, lakukan langkah 3 - 7
3. Untuk setiap data masukan X , lakukan langkah 4 - 6
4. Untuk setiap neuron j , hitung $d_j = \sum_i (w_{ij} - x_i)^2$, $i=1, \dots, N$, N adalah dimensi data (N)
5. Menentukan indeks dari sejumlah neuron, yaitu d_j , yang mempunyai nilai terkecil
6. Perbarui bobot hitung $w_{ij}^{baru} = w_{ij}^{lama} + \alpha(x_i - w_{ij}^{lama})$
7. Perbarui laju pembelajaran
8. Uji kondisi penghentian

3.7 Validasi Klaster Menggunakan DBI

Penelitian ini menggunakan metode evaluasi klaster dengan mengukur seberapa baik kelompok yang dihasilkan. untuk menentukan berapa jumlah klaster yang baik menggunakan metode *Davies-Bouldin Index (DBI)*. Semakin kecil nilai *DBI* maka klaster dianggap baik dengan nilai sekecil mungkin ≥ 0 .

Proses validasi *DBI* dengan menghitung *Sum of square within cluster (SSW)* sebagai metrik kohesi dalam sebuah klaster ke- i diformulasikan pada Persamaan (3.4):

$$SSW_i = \frac{1}{m_i} \sum_{j=1}^{m_i} d(x_j, c_i) \quad (3.4)$$

Sementara metrik untuk separasi antara dua klaster, digunakan formula *sum of square between cluster (SSB)* dengan mengukur jarak antara *centroid* c_i dan c_j diformulasikan pada Persamaan (3.5).

$$SSB_{i,j} = d(c_i, c_j) \quad (3.5)$$

R_{ij} mengukur seberapa baik nilai perbandingan antara kluster ke- i dan kluster ke- j . nilainya didapatkan dari komponen kohesi dan separasi. Kluster yang baik adalah yang mempunyai kohesi sekecil mungkin dan separasi sebesar mungkin. R_{ij} diformulasikan pada Persamaan (3.6).

$$R_{i,j} = \frac{SSW_i + SSW_j}{SSB_{i,j}} \quad (3.6)$$

Nilai *Davies-Bouldin Index (DBI)* difomulasikan pada Persamaan (3.7).

$$DBI = \frac{1}{K} \sum_{i=1}^K \max_{i \neq j} (R_{i,j}) \quad (3.7)$$

Dimana K adalah jumlah kluster yang digunakan.

3.8 Penentuan Jumlah Kluster Terbaik

Jumlah kluster terbaik ditentukan berdasarkan nilai *DBI* yang dihasilkan dari masing-masing uji coba klastering. Semakin kecil nilai *DBI* maka kluster yang dihasilkan dianggap semakin baik.

3.9 Analisis Kluster Terbaik

Proses analisis data hasil kalster hanya dilakukan pada hasil klastering yang dianggap terbaik. Artinya nilai *DBI* yang dihasilkan adalah paling minimum dari seluruh uji coba yang dilakukan. Pertama analisis kluster dilakukan berdasarkan seluruh indikator PDRB. Kedua analisis kluster dilakukan berdasarkan masing-masing indikator PDRB.

3.10 Informasi

Setelah analisis data hasil kluster terbaik dilakukan, menghasilkan informasi dan pengetahuan sehingga nantinya dapat diambil kesimpulan untuk mendukung tujuan penelitian.

BAB 4

HASIL DAN PEMBAHASAN

4.1 Hasil Uji Coba Klaster

Proses klastering dilakukan menggunakan metode *K-Means* dan *Self-Organizing Maps (SOM)*. Uji coba yang akan dilakukan pada masing-masing metode dengan menentukan jumlah klaster dari 3 sampai 10.

4.1.1 Hasil Klastering Menggunakan *K-Means*

4.1.1.1 Hasil Uji Coba Pada 3 Klaster

Uji coba klastering pada 3 klaster dilakukan dengan menentukan titik *centroid* awal secara *random* dan menghasilkan titik *centroid* akhir seperti diperlihatkan pada Tabel 4.1.

Tabel 4.1 *Centroid* Akhir 3 Klaster

Attribute	C1	C2	C3
PRT	0.3817	0.0124	0.0772
PTM	0.0860	0.0000	0.0068
IP	0.1237	0.2789	0.0104
PLG	0.0788	0.2064	0.0038
PAP	0.0763	0.3816	0.0194
KONS	0.1128	0.7674	0.0182
PER	0.0697	0.6463	0.0134
TRA	0.0889	0.6753	0.0265
PAM	0.0192	0.4069	0.0055
IK	0.0390	0.5590	0.0078
JK	0.0131	0.3072	0.0030
RE	0.0374	0.5524	0.0083
JP	0.0053	0.4897	0.0013
AP	0.0304	0.3658	0.0122
JPEN	0.0504	0.6307	0.0158
JKES	0.0448	0.6296	0.0175
JL	0.0266	0.4953	0.0068

Tabel 4.2 Distribusi Data 3 Klaster

Klaster	Distribusi Data
1	53 (11.83%)
2	7 (1.56%)
3	388 (86.60%)

Sebaran hasil klastering data pada masing-masing klaster diperlihatkan pada Tabel 4.2. Kabupaten/Kota yang masuk ke dalam klaster 1 sebanyak 53, klaster 2 sebanyak 7, klaster 3 sebanyak 388. Nilai *DBI* diperlihatkan pada Tabel 4.3.

Tabel 4.3 Rasio Klaster

Klaster	Rasio	<i>DBI</i>
1	1.2834	1.1015
2	0.7375	
3	1.2834	

4.1.1.2 Hasil Uji Coba Pada 4 Klaster

Uji coba klastering pada 4 klaster dilakukan dengan menentukan titik *centroid* awal secara *random* dan menghasilkan titik *centroid* akhir seperti diperlihatkan pada Tabel 4.4.

Tabel 4.4 *Centroid* Akhir 4 Klaster

Attribute	C1	C2	C3	C4
PRT	0.4618	0.0131	0.0784	0.0935
PTM	0.1112	0.0000	0.0068	0.0068
IP	0.0604	0.2906	0.0104	0.2921
PLG	0.0110	0.2365	0.0025	0.2845
PAP	0.0310	0.3530	0.0166	0.2967
KONS	0.0640	0.8478	0.0179	0.2550
PER	0.0457	0.6740	0.0131	0.1639
TRA	0.0438	0.6473	0.0251	0.2920
PAM	0.0108	0.4501	0.0055	0.0500
IK	0.0213	0.5900	0.0078	0.1060
JK	0.0057	0.3411	0.0029	0.0398
RE	0.0169	0.6333	0.0084	0.0902
JP	0.0020	0.5656	0.0012	0.0162
AP	0.0242	0.4063	0.0122	0.0508
JPEN	0.0321	0.6976	0.0159	0.1066
JKES	0.0252	0.6963	0.0174	0.1113
JL	0.0169	0.5314	0.0066	0.0709

Tabel 4.5 Distribusi Data 4 Klaster

Klaster	Distribusi Data
1	40 (8.92%)
2	6 (1.33%)
3	387 (86.38%)
4	15 (3.34%)

Sebaran hasil klastering data pada masing-masing klaster diperlihatkan pada Tabel 4.5. Kabupaten/Kota yang masuk ke dalam klaster 1 sebanyak 40, klaster 2 sebanyak 6, klaster 3 sebanyak 387, klaster 4 sebanyak 15. Nilai *DBI* diperlihatkan pada Tabel 4.6.

Tabel 4.6 Rasio Klaster

Klaster	Rasio	<i>DBI</i>
1	1.1717	1.0595
2	0.8875	
3	1.0071	
4	1.1717	

4.1.1.3 Hasil Uji Coba Pada 5 Klaster

Uji coba klastering pada 5 klaster dilakukan dengan menentukan titik *centroid* awal secara *random* dan menghasilkan titik *centroid* akhir Seperti diperlihatkan pada Tabel 4.7.

Tabel 4.7 *Centroid* Akhir 5 Klaster

Attribute	C1	C2	C3	C4	C5
PRT	0.1054	0.0131	0.079	0.0964	0.4801
PTM	0.0078	0.0000	0.0069	0.0079	0.1205
IP	0.3216	0.2906	0.0057	0.1055	0.0420
PLG	0.3162	0.2365	0.0012	0.0344	0.0042
PAP	0.2582	0.3530	0.0125	0.1104	0.0279
KONS	0.2785	0.8478	0.0135	0.0995	0.0533
PER	0.1843	0.6740	0.0103	0.0625	0.0393
TRA	0.3071	0.6473	0.0181	0.1423	0.0316
PAM	0.0560	0.4501	0.0033	0.0366	0.0080
IK	0.1180	0.5900	0.0058	0.0400	0.0186
JK	0.0437	0.3411	0.0021	0.0154	0.0051
RE	0.1008	0.6333	0.0062	0.0410	0.0146
JP	0.0182	0.5656	0.0008	0.0076	0.0015
AP	0.0568	0.4063	0.0108	0.0332	0.0234
JPEN	0.1199	0.6976	0.0127	0.0607	0.0302
JKES	0.1245	0.6963	0.0137	0.0691	0.0221
JL	0.0801	0.5314	0.0050	0.0312	0.0148

Tabel 4.8 Distribusi Data 5 Klaster

Klaster	Distribusi Data
1	13 (2.90%)
2	6 (1.33%)
3	364 (81.25%)

4	29 (6.47%)
5	36 (8.03%)

Sebaran hasil klastering data pada masing-masing klaster diperlihatkan pada Tabel 4.8. Kabupaten/Kota yang masuk ke dalam klaster 1 sebanyak 13, klaster 2 sebanyak 6, klaster 3 sebanyak 364, klaster 4 sebanyak 29, klaster 5 sebanyak 36. Nilai *DBI* diperlihatkan pada Tabel 4.9.

Tabel 4.9 Rasio Klaster

Klaster	Rasio	<i>DBI</i>
1	1.6916	1.3799
2	0.8984	
3	1.4518	
4	1.6916	
5	1.1659	

4.1.1.4 Hasil Uji Coba Pada 6 Klaster

Uji coba klastering dengan 6 klaster dilakukan dengan menentukan titik *centroid* awal secara *random* dan menghasilkan titik *centroid* akhir seperti diperlihatkan pada Tabel 4.10.

Tabel 4.10 *Centroid* Akhir 6 Klaster

Attribute	C1	C2	C3	C4	C5	C6
PRT	0.0642	0.0131	0.0396	0.1035	0.4861	0.1687
PTM	0.0052	0.0000	0.0045	0.0078	0.1189	0.0137
IP	0.0599	0.2906	0.0055	0.3130	0.0576	0.0177
PLG	0.0271	0.2365	0.0008	0.3273	0.0115	0.0023
PAP	0.1109	0.3530	0.0109	0.3043	0.0314	0.0172
KONS	0.1175	0.8478	0.0103	0.2551	0.0620	0.0237
PER	0.0728	0.6740	0.0073	0.1703	0.0436	0.0190
TRA	0.1863	0.6473	0.0142	0.2966	0.0346	0.0285
PAM	0.0449	0.4501	0.0021	0.0526	0.0101	0.0067
IK	0.0527	0.5900	0.0043	0.1007	0.0220	0.0102
JK	0.0211	0.3411	0.0017	0.0389	0.0053	0.0035
RE	0.0557	0.6333	0.0047	0.0906	0.0151	0.0103
JP	0.0109	0.5656	0.0008	0.0159	0.0017	0.0010
AP	0.0421	0.4063	0.0092	0.0507	0.0233	0.0149
JPEN	0.0881	0.6976	0.0087	0.0906	0.0299	0.0235
JKES	0.1022	0.6963	0.0114	0.0967	0.0226	0.0200
JL	0.0404	0.5314	0.0035	0.0706	0.0157	0.0094

Tabel 4.11 Distribusi Data 6 Klaster

Klaster	Distribusi Data
1	20 (4.46%)
2	6 (1.33%)
3	252 (56.25%)
4	13 (2.90%)
5	35 (7.81%)
6	122 (27.23%)

Sebaran hasil klastering data pada masing-masing klaster diperlihatkan pada Tabel 4.11. Kabupaten/Kota yang masuk ke-klaster 1 sebanyak 20, klaster 2 sebanyak 6, klaster 3 sebanyak 252, klaster 4 sebanyak 13, klaster 5 sebanyak 35, klaster 6 sebanyak 122. Nilai *DBI* diperlihatkan pada Tabel 4.12.

Tabel 4.12 Rasio Klaster

Klaster	Rasio	<i>DBI</i>
1	1.7226	1.2769
2	0.8899	
3	1.0293	
4	1.7226	
5	1.1241	
6	1.1729	

4.1.1.5 Hasil Uji Coba Pada 7 Klaster

Uji coba klastering dengan 7 klaster dilakukan dengan menentukan titik *centroid* awal secara *random* dan menghasilkan titik *centroid* akhir seperti diperlihatkan pada Tabel 4.13.

Tabel 4.13 *Centroid* Akhir 7 Klaster

Attribute	C1	C2	C3	C4	C5	C6	C7
PRT	0.0929	0.0131	0.0479	0.1182	0.2097	0.0887	0.5669
PTM	0.0055	0.0000	0.0050	0.0105	0.0178	0.0081	0.1747
IP	0.2361	0.2906	0.0032	0.3999	0.0177	0.1129	0.0539
PLG	0.0649	0.2365	0.0009	0.5723	0.0027	0.0459	0.0036
PAP	0.3398	0.3530	0.0114	0.3162	0.0194	0.0800	0.0285
KONS	0.3539	0.8478	0.0110	0.1712	0.0279	0.1054	0.0553
PER	0.2475	0.6740	0.0075	0.0863	0.0235	0.0687	0.0409
TRA	0.4232	0.6473	0.0152	0.1190	0.0281	0.1688	0.0320
PAM	0.0769	0.4501	0.0027	0.0247	0.0067	0.0378	0.0095
IK	0.1854	0.5900	0.0047	0.0350	0.0127	0.0388	0.0167
JK	0.0585	0.3411	0.0018	0.0234	0.0038	0.0162	0.0050
RE	0.1262	0.6333	0.0054	0.0659	0.0108	0.0422	0.0138

JP	0.0276	0.5656	0.0008	0.0062	0.0011	0.0081	0.0016
AP	0.0792	0.4063	0.0098	0.0254	0.0163	0.0334	0.0234
JPEN	0.1756	0.6976	0.0094	0.0463	0.0261	0.0607	0.0316
JKES	0.1738	0.6963	0.0125	0.0531	0.0204	0.0705	0.0218
JL	0.1044	0.5314	0.0037	0.0387	0.0111	0.0332	0.0147

Tabel 4.14 Distribusi Data 7 Klaster

Klaster	Distribusi Data
1	7 (1.56%)
2	6 (1.33%)
3	281 (62.72%)
4	6 (1.33%)
5	101 (22.54%)
6	26 (5.80%)
7	21 (4.68%)

Sebaran hasil klastering data pada masing-masing klaster diperlihatkan pada Tabel 4.14. Kabupaten/Kota yang masuk ke-klaster 1 sebanyak 7, klaster 2 sebanyak 6, klaster 3 sebanyak 281, klaster 4 sebanyak 6, klaster 5 sebanyak 101, klaster 6 sebanyak 26, klaster 7 sebanyak 21. Nilai *DBI* diperlihatkan pada Tabel 4.15.

Tabel 4.15 Rasio Klaster

Klaster	Rasio	<i>DBI</i>
1	1.4233	1.2415
2	0.9103	
3	1.1915	
4	1.4233	
5	1.3671	
6	1.3671	
7	1.0076	

4.1.1.6 Hasil Uji Coba Pada 8 Klaster

Uji coba klastering dengan 8 klaster dilakukan dengan menentukan titik *centroid* awal secara *random* dan menghasilkan titik *centroid* akhir seperti diperlihatkan pada Tabel 4.16.

Tabel 4.16 *Centroid* Akhir 8 Klaster

Attribute	C1	C2	C3	C4	C5	C6	C7	C8
PRT	0.0929	0.0131	0.0397	0.1182	0.5131	0.1703	0.4058	0.0873
PTM	0.0055	0.0000	0.0045	0.0105	0.0484	0.0154	0.8255	0.0082
IP	0.2361	0.2906	0.0028	0.3999	0.0462	0.0139	0.0359	0.1170
PLG	0.0649	0.2365	0.0009	0.5723	0.0046	0.0021	0.0029	0.0477
PAP	0.3398	0.3530	0.0110	0.3162	0.0287	0.0172	0.0296	0.0829
KONS	0.3539	0.8478	0.0102	0.1712	0.0509	0.0232	0.0837	0.1088
PER	0.2475	0.6740	0.0071	0.0863	0.0407	0.0188	0.0372	0.0710
TRA	0.4232	0.6473	0.0143	0.1190	0.0320	0.0279	0.0410	0.1668
PAM	0.0769	0.4501	0.0023	0.0247	0.0087	0.0065	0.0046	0.0393
IK	0.1854	0.5900	0.0044	0.035	0.0188	0.0106	0.0097	0.0400
JK	0.0585	0.3411	0.0017	0.0234	0.0052	0.0033	0.0027	0.0167
RE	0.1262	0.6333	0.005	0.0659	0.0145	0.0099	0.0119	0.0437
JP	0.0276	0.5656	0.0008	0.0062	0.0016	0.0009	0.0010	0.0084
AP	0.0792	0.4063	0.0094	0.0254	0.0215	0.0151	0.0295	0.0341
JPEN	0.1756	0.6976	0.0089	0.0463	0.0302	0.0230	0.0296	0.0621
JKES	0.1738	0.6963	0.0117	0.0531	0.0208	0.0199	0.0336	0.0729
JL	0.1044	0.5314	0.0036	0.0387	0.0154	0.0093	0.0083	0.0342

Tabel 4.17 Distribusi Data 8 Klaster

Klaster	Distribusi Data
1	7 (1.56%)
2	6 (1.33%)
3	251 (56.02%)
4	6 (1.33%)
5	29 (6.47%)
6	121 (27.00%)
7	3 (0.66%)
8	25 (5.58%)

Sebaran hasil klastering data pada masing-masing klaster diperlihatkan pada Tabel 4.17. Kabupaten/Kota yang masuk ke dalam klaster 1 sebanyak 7, klaster 2 sebanyak 6, klaster 3 sebanyak 251, klaster 4 sebanyak 6, klaster 5 sebanyak 29, klaster 6 sebanyak 121, klaster 7 sebanyak 3, klaster 8 sebanyak 25. Nilai *DBI* diperlihatkan pada Tabel 4.18.

Tabel 4.18 Rasio Klaster

Klaster	Rasio	<i>DBI</i>
1	1.4233	1.1490
2	0.9103	
3	1.1450	

4	1.4233	
5	0.9226	
6	1.3470	
7	0.6737	
8	1.3470	

4.1.1.7 Hasil Uji Coba Pada 9 Klaster

Uji coba klastering dengan 9 klaster dilakukan dengan menentukan titik *centroid* awal secara *random* dan menghasilkan titik *centroid* akhir seperti diperlihatkan pada Tabel 4.19.

Tabel 4.19 *Centroid* Akhir 9 Klaster

Attribute	C1	C2	C3	C4	C5	C6	C7	C8	C9
PRT	0.0929	0.0131	0.0306	0.1182	0.5377	0.2193	0.4058	0.0821	0.1101
PTM	0.0055	0.0000	0.0024	0.0105	0.0553	0.0185	0.8255	0.0085	0.0126
IP	0.2361	0.2906	0.0023	0.3999	0.0493	0.0223	0.0359	0.1159	0.0067
PLG	0.0649	0.2365	0.0008	0.5723	0.0037	0.0036	0.0029	0.0488	0.0012
PAP	0.3398	0.3530	0.0099	0.3162	0.0278	0.0208	0.0296	0.0853	0.0153
KONS	0.3539	0.8478	0.0088	0.1712	0.0527	0.0301	0.0837	0.1091	0.0177
PER	0.2475	0.6740	0.0063	0.0863	0.0421	0.0258	0.0372	0.0721	0.0118
TRA	0.4232	0.6473	0.0117	0.1190	0.0319	0.0287	0.0410	0.1699	0.0274
PAM	0.0769	0.4501	0.0020	0.0247	0.0092	0.0083	0.0046	0.0399	0.0044
IK	0.1854	0.5900	0.0037	0.0350	0.0187	0.0137	0.0097	0.0412	0.0076
JK	0.0585	0.3411	0.0016	0.0234	0.0053	0.0044	0.0027	0.0169	0.0024
RE	0.1262	0.6333	0.0042	0.0659	0.0145	0.0125	0.0119	0.0426	0.0085
JP	0.0276	0.5656	0.0006	0.0062	0.0016	0.0013	0.0010	0.0086	0.0010
AP	0.0792	0.4063	0.0089	0.0254	0.0223	0.0170	0.0295	0.0344	0.0128
JPEN	0.1756	0.6976	0.0081	0.0463	0.0303	0.0297	0.0296	0.0613	0.0152
JKES	0.1738	0.6963	0.0105	0.0531	0.0208	0.0211	0.0336	0.0745	0.0182
JL	0.1044	0.5314	0.0031	0.0387	0.0156	0.0125	0.0083	0.0344	0.0063

Tabel 4.20 Distribusi Data 9 Klaster

Klaster	Distribusi Data
1	7 (1.56%)
2	6 (1.33%)
3	206 (45.98%)
4	6 (1.33%)
5	25 (5.58%)
6	65 (14.50%)
7	3 (1.33%)
8	24 (5.35%)
9	106 (23.66%)

Sebaran hasil klastering data pada masing-masing klaster diperlihatkan pada Tabel 4.20. Kabupaten/Kota yang masuk ke-klaster 1 sebanyak 7, klaster 2

sebanyak 6, klaster 3 sebanyak 206, klaster 4 sebanyak 6, klaster 5 sebanyak 25, klaster 6 sebanyak 65, klaster 7 sebanyak 3, klaster 8 sebanyak 24, klaster 9 sebanyak 106. Nilai *DBI* diperlihatkan pada Tabel 4.21.

Tabel 4.21 Rasio Klaster

Klaster	Rasio	<i>DBI</i>
1	1.4233	1.1483
2	0.9103	
3	1.0981	
4	1.4233	
5	0.8841	
6	1.3073	
7	0.6737	
8	1.3168	
9	1.2974	

4.1.1.8 Hasil Uji Coba Pada 10 Klaster

Uji coba klastering dengan 10 klaster dilakukan dengan menentukan titik *centroid* awal secara *random* dan menghasilkan titik *centroid* akhir seperti diperlihatkan pada Tabel 4.22.

Tabel 4.22 *Centroid* Akhir 10 Klaster

Attribute	C1	C2	C3	C4	C5	C6	C7	C8	C9	C10
PRT	0.0929	0.0131	0.0293	0.1182	0.3751	0.1955	0.6445	0.0373	0.1007	0.4058
PTM	0.0055	0.0000	0.0024	0.0105	0.0311	0.0146	0.0763	0.0045	0.0130	0.8255
IP	0.2361	0.2906	0.0019	0.3999	0.0702	0.0196	0.0521	0.0903	0.0068	0.0359
PLG	0.0649	0.2365	0.0008	0.5723	0.0169	0.0029	0.0030	0.0424	0.0011	0.0029
PAP	0.3398	0.3530	0.0096	0.3162	0.0379	0.0181	0.0209	0.0893	0.0153	0.0296
KONS	0.3539	0.8478	0.0084	0.1712	0.0715	0.0269	0.0466	0.0958	0.0172	0.0837
PER	0.2475	0.6740	0.0060	0.0863	0.0521	0.0233	0.0387	0.0635	0.0112	0.0372
TRA	0.4232	0.6473	0.0114	0.1190	0.0544	0.0282	0.0289	0.1675	0.0265	0.0410
PAM	0.0769	0.4501	0.0017	0.0247	0.0133	0.0076	0.0087	0.0414	0.0043	0.0046
IK	0.1854	0.5900	0.0035	0.0350	0.0261	0.0119	0.0170	0.0415	0.0069	0.0097
JK	0.0585	0.3411	0.0015	0.0234	0.0062	0.0041	0.0051	0.0180	0.0022	0.0027
RE	0.1262	0.6333	0.0038	0.0659	0.0196	0.0115	0.0131	0.0449	0.0081	0.0119
JP	0.0276	0.5656	0.0006	0.0062	0.0025	0.0011	0.0013	0.0090	0.0011	0.0010
AP	0.0792	0.4063	0.0086	0.0254	0.0244	0.0160	0.0218	0.0360	0.0123	0.0295
JPEN	0.1756	0.6976	0.0077	0.0463	0.0323	0.0283	0.0322	0.0652	0.0136	0.0296
JKES	0.1738	0.6963	0.0100	0.0531	0.0286	0.0205	0.0178	0.0807	0.0175	0.0336
JL	0.1044	0.5314	0.0029	0.0387	0.0193	0.0113	0.0150	0.0342	0.0057	0.0083

Tabel 4.23 Distribusi Data 10 Klaster

Klaster	Distribusi Data
1	7 (1.56%)
2	6 (1.33%)
3	198 (44.19%)

4	6 (1.33%)
5	23 (5.13%)
6	72 (15.84%)
7	13 (2.90%)
8	21 (4.68%)
9	99 (22.09%)
10	3 (0.66%)

Sebaran hasil klastering data pada masing-masing klaster diperlihatkan pada Tabel 4.23. Kabupaten/Kota yang masuk ke-klaster 1 sebanyak 7, klaster 2 sebanyak 6, klaster 3 sebanyak 198, klaster 4 sebanyak 6, klaster 5 sebanyak 23, klaster 6 sebanyak 72, klaster 7 sebanyak 13, klaster 8 sebanyak 21, klaster 9 sebanyak 99, klaster 10 sebanyak 3. Nilai *DBI* diperlihatkan pada Tabel 4.24.

Tabel 4.24 Rasio Klaster

Klaster	Rasio	<i>DBI</i>
1	1.4233	1.1502
2	0.9103	
3	1.1026	
4	1.4233	
5	1.1471	
6	1.1732	
7	1.1471	
8	1.2505	
9	1.2505	
10	0.6737	

4.1.2 Hasil Klastering Menggunakan *SOM*

4.1.2.1 Hasil Uji Coba Pada 3 Klaster

Pada klastering dengan 3 klaster ini dilakukan dengan memberikan *learning rate* 0.1 dan nilai *Epochs* sebesar 200. Bobot akhir yang didapatkan diperlihatkan pada Tabel 4.25.

Tabel 4.25 Bobot Akhir 3 Klaster

C1	C2	C3
0.3627	0.0766	0.0134
0.0751	0.0072	0.0000
0.1073	0.0085	0.3420
0.0708	0.0028	0.2660
0.0901	0.0185	0.3859
0.1222	0.0162	0.8173

0.0816	0.0120	0.6753
0.1148	0.0223	0.7006
0.0260	0.0042	0.4713
0.0456	0.0074	0.5176
0.0160	0.0027	0.3014
0.0394	0.0079	0.5599
0.0063	0.0011	0.4787
0.0318	0.0118	0.3374
0.0551	0.0150	0.6861
0.0524	0.0168	0.6356
0.0334	0.0063	0.4376

Tabel 4.26 Distribusi Data 3 Klaster dan Nilai *DBI*

Klaster	Distribusi Data	Rasio	<i>DBI</i>
1	59 (13.16%)	1.3440	1.1367
2	383 (85.49%)	1.3440	
3	6 (1.33%)	0.7220	

Sebaran hasil klastering data pada masing-masing klaster diperlihatkan pada Tabel 4.26. Kabupaten/Kota masuk ke dalam klaster 2 sebanyak 383 dengan nilai rasio sebesar 1.3440, klaster 1 sebanyak 59 dengan nilai rasio sebesar 1.3440, dan klaster 3 sebanyak 6 dengan nilai rasio 0.7220. Berdasarkan Tabel 4.26 nilai *DBI* 3 klaster sebesar 1.1367.

4.1.2.2 Hasil Uji Coba Pada 4 Klaster

Pada klastering dengan 4 klaster ini dilakukan dengan memberikan *learning rate* 0.1 dan nilai *Epochs* sebesar 200. Bobot akhir yang didapatkan diperlihatkan pada Tabel 4.27.

Tabel 4.27 Bobot Akhir 4 Klaster

C1	C2	C3	C4
0.0777	0.0935	0.4669	0.0130
0.0063	0.0068	0.1169	0.0000
0.0102	0.2921	0.0600	0.2906
0.0026	0.2845	0.0111	0.2365
0.0161	0.2967	0.0309	0.3530
0.0168	0.2550	0.0617	0.8478
0.0126	0.1639	0.0447	0.6740
0.0234	0.2920	0.0367	0.6472
0.0053	0.0500	0.0105	0.4501

0.0075	0.1060	0.0217	0.5900
0.0028	0.0398	0.0052	0.3411
0.0078	0.0902	0.0153	0.6332
0.0012	0.0162	0.0019	0.5656
0.0118	0.0508	0.0241	0.4063
0.0153	0.1066	0.0321	0.6976
0.0169	0.1113	0.0239	0.6963
0.0065	0.0709	0.0174	0.5314

Tabel 4.28 Distribusi Data 4 Klaster dan Nilai *DBI*

Klaster	Distribusi Data	Rasio	<i>DBI</i>
1	387 (86.38%)	1.0034	1.0538
2	15 (3.34%)	1.1620	
3	40 (8.92%)	1.1620	
4	6 (1.33%)	0.8876	

Sebaran hasil klastering data pada masing-masing klaster diperlihatkan pada Tabel 4.28. Klaster 1 sebanyak 387 dengan nilai rasio sebesar 1.0034, klaster 2 sebanyak 15 dengan nilai rasio 1.1620, klaster 3 sebanyak 40 dengan nilai rasio 1.1620, klaster 4 sebanyak 6 dengan nilai rasio 0.8876. Berdasarkan Tabel 4.28 nilai *DBI* 4 klaster sebesar 1.0538.

4.1.2.3 Hasil Uji Coba Pada 5 Klaster

Pada klastering dengan 5 klaster ini dilakukan dengan memberikan *learning rate* 0.1 dan nilai *Epochs* sebesar 200. Bobot akhir yang didapatkan diperlihatkan pada Tabel 4.29.

Tabel 4.29 Bobot Akhir 5 Klaster

C1	C2	C3	C4	C5
0.0448	0.1114	0.1799	0.5213	0.0130
0.0050	0.0085	0.0151	0.1511	0.0000
0.0068	0.3217	0.0301	0.0404	0.2906
0.0025	0.3525	0.0057	0.0035	0.2365
0.0146	0.2835	0.0262	0.0273	0.3530
0.0128	0.2526	0.0398	0.0572	0.8478
0.0093	0.1445	0.0281	0.0399	0.6740
0.0187	0.2510	0.0508	0.0286	0.6472
0.0033	0.0447	0.0127	0.0082	0.4501
0.0055	0.0780	0.0164	0.0201	0.5900
0.0023	0.0334	0.0055	0.0052	0.3411

0.0056	0.0925	0.0175	0.0147	0.6332
0.0010	0.0143	0.0022	0.0014	0.5656
0.0103	0.0447	0.0190	0.0238	0.4063
0.0108	0.0790	0.0314	0.0290	0.6976
0.0144	0.0856	0.0280	0.0215	0.6963
0.0046	0.0533	0.0134	0.0148	0.5314

Tabel 4.30 Distribusi Data 5 Klaster dan Nilai *DBI*

Klaster	Distribusi Data	Rasio	<i>DBI</i>
1	281 (62.72%)	1.1467	1.0820
2	14 (3.12%)	1.1271	
3	118 (26.33%)	1.1467	
4	29 (6.47%)	1.1193	
5	6 (1.33%)	0.8704	

Sebaran hasil klastering data pada masing-masing klaster diperlihatkan pada Tabel 4.30. Klaster 1 sebanyak 281 dengan nilai rasio sebesar 1.1467, klaster 2 sebanyak 14 dengan nilai rasio 1.1271, klaster 3 sebanyak 118 dengan nilai rasio 1.1467, klaster 4 sebanyak 29 dengan nilai rasio 1.1193, klaster 5 sebanyak 6 dengan nilai rasio 0.8704. Berdasarkan Tabel 4.30 nilai *DBI* 5 klaster sebesar 1.0820.

4.1.2.4 Hasil Uji Coba Pada 6 Klaster

Pada klastering dengan 6 klaster ini dilakukan dengan memberikan *learning rate* 0.1 dan nilai *Epochs* sebesar 200. Bobot akhir yang didapatkan diperlihatkan pada Tabel 4.31.

Tabel 4.31 Bobot Akhir 6 Klaster

C1	C2	C3	C4	C5	C6
0.0434	0.0716	0.1852	0.5345	0.1649	0.0134
0.0053	0.0040	0.0138	0.1274	0.0156	0.0000
0.0080	0.1887	0.0228	0.0495	0.5136	0.3420
0.0010	0.0924	0.0054	0.0039	0.7387	0.2660
0.0148	0.2412	0.0215	0.0289	0.1418	0.3859
0.0135	0.2861	0.0298	0.0573	0.1628	0.8173
0.0092	0.1778	0.0230	0.0436	0.1134	0.6753
0.0188	0.3692	0.0373	0.0331	0.1228	0.7006
0.0034	0.0689	0.0096	0.0092	0.0243	0.4713
0.0059	0.1223	0.0128	0.0201	0.0391	0.5176
0.0023	0.0431	0.0042	0.0053	0.0249	0.3014

0.0068	0.0887	0.0129	0.0149	0.0866	0.5599
0.0011	0.0176	0.0014	0.0016	0.0092	0.4787
0.0104	0.0610	0.0165	0.0246	0.0311	0.3374
0.0116	0.1170	0.0272	0.0309	0.0589	0.6861
0.0152	0.1258	0.0228	0.0237	0.0544	0.6356
0.0049	0.0723	0.0109	0.0158	0.0529	0.4376

Tabel 4.32 Distribusi Data 6 Klaster dan Nilai *DBI*

Klaster	Distribusi Data	Rasio	<i>DBI</i>
1	278 (62.05%)	0.9970	1.0333
2	15 (3.34%)	1.1532	
3	117 (26.11%)	0.9970	
4	28 (6.25%)	0.9833	
5	4 (0.89%)	1.1532	
6	6 (1.33%)	0.9162	

Sebaran hasil klastering data pada masing-masing klaster diperlihatkan pada Tabel 4.32. Klaster 1 sebanyak 278 dengan nilai rasio sebesar 0.9970, klaster 2 sebanyak 15 dengan nilai rasio 1.1532, klaster 3 sebanyak 117 dengan nilai rasio 0.9970, klaster 4 sebanyak 28 dengan nilai rasio 0.9833, klaster 5 sebanyak 4 dengan nilai rasio 1.1532, klaster 6 sebanyak 6 dengan nilai rasio 0.9162. Berdasarkan Tabel 4.32 nilai *DBI* 6 klaster sebesar 1.0333.

4.1.2.5 Hasil Uji Coba Pada 7 Klaster

Pada klastering dengan 7 klaster ini dilakukan dengan memberikan *learning rate* 0.1 dan nilai *Epochs* sebesar 200. Bobot akhir yang didapatkan diperlihatkan pada Tabel 4.33.

Tabel 4.33 Bobot Akhir 7 Klaster

C1	C2	C3	C4	C5	C6	C7
0.0414	0.1717	0.0853	0.4967	0.4058	0.1944	0.013
0.0050	0.0105	0.0058	0.0515	0.8255	0.0134	0.0000
0.0047	0.0226	0.2274	0.0639	0.0359	0.6031	0.2906
0.0010	0.0028	0.1263	0.0127	0.0029	0.8176	0.2365
0.0144	0.0205	0.3204	0.0290	0.0296	0.0878	0.3530
0.0128	0.0304	0.2564	0.0612	0.0837	0.2342	0.8478
0.0084	0.0236	0.1681	0.0426	0.0372	0.1114	0.6740
0.0192	0.0381	0.3448	0.0421	0.0410	0.1283	0.6472
0.0031	0.0094	0.0674	0.0101	0.0046	0.0227	0.4501
0.0058	0.0125	0.1163	0.0189	0.0097	0.0575	0.5900

0.0023	0.0045	0.0404	0.0057	0.0027	0.0327	0.3411
0.0068	0.0132	0.0812	0.0166	0.0119	0.1069	0.6332
0.0012	0.0014	0.0165	0.0017	0.0010	0.0150	0.5656
0.0105	0.0172	0.0541	0.0210	0.0295	0.0365	0.4063
0.0108	0.0279	0.1121	0.0250	0.0296	0.0830	0.6976
0.0149	0.0234	0.1198	0.0204	0.0336	0.0503	0.6963
0.0045	0.0115	0.0705	0.0134	0.0083	0.0631	0.5314

Tabel 4.34 Distribusi Data 7 Klaster dan Nilai *DBI*

Klaster	Distribusi Data	Rasio	<i>DBI</i>
1	273 (60.93%)	1.0484	0.9704
2	118 (26.33%)	1.0484	
3	12 (2.67%)	1.1162	
4	32 (7.14%)	0.9656	
5	3 (0.66%)	0.6554	
6	4 (0.89%)	1.1162	
7	6 (1.33%)	0.8428	

Sebaran hasil klastering data pada masing-masing klaster diperlihatkan pada Tabel 4.34. Klaster 1 sebanyak 273 dengan nilai rasio sebesar 1.0484, klaster 2 sebanyak 118 dengan nilai rasio 1.0484, klaster 3 sebanyak 12 dengan nilai rasio 1.1162, klaster 4 sebanyak 32 dengan nilai rasio 0.9656, klaster 5 sebanyak 3 dengan nilai rasio 0.6554, klaster 6 sebanyak 4 dengan nilai rasio 1.1162, klaster 7 sebanyak 6 dengan nilai rasio 0.8428. Berdasarkan Tabel 4.34 nilai *DBI* 7 klaster sebesar 0.9704.

4.1.2.6 Hasil Uji Coba Pada 8 Klaster

Pada klastering dengan 8 klaster ini dilakukan dengan memberikan *learning rate* 0.1 dan nilai *Epochs* sebesar 200. Bobot akhir yang didapatkan diperlihatkan pada Tabel 4.35.

Tabel 4.35 Bobot Akhir 8 Klaster

C1	C2	C3	C4	C5	C6	C7	C8
0.0424	0.0844	0.0869	0.1814	0.5266	0.4058	0.1649	0.0130
0.0049	0.0086	0.0049	0.0162	0.0541	0.8255	0.0156	0.0000
0.0042	0.1030	0.2495	0.0163	0.0439	0.0359	0.5136	0.2906
0.0009	0.0412	0.0978	0.0024	0.0050	0.0029	0.7387	0.2365
0.0117	0.1284	0.3386	0.0171	0.0275	0.0296	0.1418	0.3530
0.0110	0.1069	0.3564	0.0249	0.0499	0.0837	0.1628	0.8478

0.0074	0.0683	0.2244	0.0202	0.0406	0.0372	0.1134	0.6740
0.0146	0.1623	0.3981	0.0301	0.0315	0.0410	0.1228	0.6472
0.0027	0.0397	0.0737	0.0067	0.0091	0.0046	0.0243	0.4501
0.0047	0.0414	0.1688	0.0111	0.0199	0.0097	0.0391	0.5900
0.0018	0.0166	0.0562	0.0036	0.0053	0.0027	0.0249	0.3411
0.0053	0.0428	0.1165	0.0107	0.0150	0.0119	0.0866	0.6332
0.0008	0.0085	0.0241	0.0010	0.0016	0.0010	0.0092	0.5656
0.0096	0.0340	0.0727	0.0159	0.0217	0.0295	0.0311	0.4063
0.0092	0.0611	0.1588	0.0247	0.0308	0.0296	0.0589	0.6976
0.0122	0.0727	0.1646	0.0206	0.0208	0.0336	0.0544	0.6963
0.0037	0.0323	0.0939	0.0101	0.0167	0.0083	0.0529	0.5314

Tabel 4.36 Distribusi Data 8 Klaster dan Nilai *DBI*

Klaster	Distribusi Data	Rasio	<i>DBI</i>
1	264 (58.92%)	1.2648	1.1405
2	24 (5.35%)	1.4547	
3	8 (1.78%)	1.4547	
4	112 (25.00%)	1.4474	
5	27 (6.02%)	0.9574	
6	3 (0.66%)	0.5768	
7	4 (0.89%)	1.0776	
8	6 (1.33%)	0.8903	

Sebaran hasil klastering data pada masing-masing klaster diperlihatkan pada Tabel 4.36. Klaster 1 sebanyak 264 dengan nilai rasio sebesar 1.2648, klaster 2 sebanyak 24 dengan nilai rasio 1.4547, klaster 3 sebanyak 8 dengan nilai rasio 1.4547, klaster 4 sebanyak 112 dengan nilai rasio 1.4474, klaster 5 sebanyak 27 dengan nilai rasio 0.9574, klaster 6 sebanyak 3 dengan nilai rasio 0.5768, klaster 7 sebanyak 4 dengan nilai rasio 1.0776, klaster 8 sebanyak 6 dengan nilai rasio 0.8903. Berdasarkan Tabel 4.36 nilai *DBI* 8 klaster sebesar 1.1405.

4.1.2.7 Hasil Uji Coba Pada 9 Klaster

Pada klastering dengan 9 klaster ini dilakukan dengan memberikan *learning rate* 0.1 dan nilai *Epochs* sebesar 200. Bobot akhir yang didapatkan diperlihatkan pada Tabel 4.37.

Tabel 4.37 Bobot Akhir 9 Klaster

C1	C2	C3	C4	C5	C6	C7	C8	C9
0.0413	0.0351	0.0925	0.1668	0.3872	0.655	0.4058	0.2174	0.0136
0.0049	0.0056	0.0053	0.0145	0.0252	0.0822	0.8255	0.0207	0.0000
0.0042	0.0470	0.2577	0.0156	0.0603	0.0544	0.0359	0.6087	0.3275
0.0008	0.0657	0.1087	0.0022	0.0085	0.0030	0.0029	0.6516	0.2549
0.0104	0.1774	0.3617	0.0170	0.0384	0.0200	0.0296	0.1061	0.3762
0.0104	0.0829	0.3224	0.0221	0.0580	0.0486	0.0837	0.1899	0.8372
0.0071	0.0572	0.2320	0.0183	0.0527	0.0377	0.0372	0.1260	0.6937
0.0142	0.2056	0.4214	0.0285	0.0487	0.0276	0.0410	0.1277	0.6428
0.0024	0.0431	0.0731	0.0067	0.0120	0.0076	0.0046	0.0231	0.4761
0.0046	0.0344	0.1635	0.0097	0.0255	0.0168	0.0097	0.0479	0.5080
0.0018	0.0193	0.0565	0.0034	0.0058	0.0051	0.0027	0.0274	0.3683
0.0051	0.0293	0.1183	0.0096	0.0176	0.0133	0.0119	0.0745	0.6308
0.0009	0.0075	0.0249	0.0010	0.0026	0.0012	0.0010	0.0104	0.5897
0.0093	0.0360	0.0694	0.0148	0.0236	0.0223	0.0295	0.0373	0.4634
0.0092	0.0574	0.1619	0.0232	0.0368	0.0304	0.0296	0.0711	0.6984
0.0120	0.0724	0.1710	0.0198	0.0298	0.0167	0.0336	0.0496	0.6919
0.0037	0.0338	0.0980	0.0094	0.0202	0.0137	0.0083	0.0595	0.5517

Tabel 4.38 Distribusi Data 9 Klaster dan Nilai *DBI*

Klaster	Distribusi Data	Rasio	<i>DBI</i>
1	253 (56.47%)	1.1218	1.1192
2	17 (3.79%)	1.4211	
3	8 (1.78%)	1.4211	
4	121 (27.00%)	1.1905	
5	24 (5.35%)	1.1563	
6	12 (2.67%)	1.1563	
7	3 (0.66%)	0.5780	
8	4 (0.89%)	1.1365	
9	6 (1.33%)	0.8910	

Sebaran hasil klastering data pada masing-masing klaster diperlihatkan pada Tabel 4.38. Klaster 1 sebanyak 253 dengan nilai rasio sebesar 1.1218, klaster 2 sebanyak 17 dengan nilai rasio 1.4211, klaster 3 sebanyak 8 dengan nilai rasio 1.4211, klaster 4 sebanyak 121 dengan nilai rasio 1.1905, klaster 5 sebanyak 24 dengan nilai rasio 1.1563, klaster 6 sebanyak 12 dengan nilai rasio 1.1563, klaster 7 sebanyak 3 dengan nilai rasio 0.5780, klaster 8 sebanyak 4 dengan nilai rasio 1.1365, klaster 9 sebanyak 6 dengan nilai rasio 0.8910. Berdasarkan Tabel 4.38 nilai *DBI* 9 klaster sebesar 1.1192.

4.1.2.8 Hasil Uji Coba Pada 10 Klaster

Pada klastering dengan 10 klaster ini dilakukan dengan memberikan *learning rate* 0.1 dan nilai *Epochs* sebesar 200. Bobot akhir yang didapatkan diperlihatkan pada Tabel 4.39.

Tabel 4.39 Bobot Akhir 10 Klaster

C1	C2	C3	C4	C5	C6	C7	C8	C9	C10
0.0398	0.0321	0.0044	0.1667	0.3808	0.6486	0.4058	0.1649	0.0869	0.0130
0.0048	0.0048	0.0002	0.0149	0.0319	0.0821	0.8255	0.0156	0.0049	0.0000
0.0047	0.0509	0.0019	0.0186	0.0633	0.0551	0.0359	0.5136	0.2495	0.2906
0.0009	0.0542	0.1503	0.0024	0.0170	0.0029	0.0029	0.7387	0.0978	0.2365
0.0106	0.0928	1.0000	0.0173	0.0379	0.0202	0.0296	0.1418	0.3386	0.3530
0.0103	0.1104	0.0013	0.0238	0.0710	0.0472	0.0837	0.1628	0.3564	0.8478
0.0076	0.0701	0.0012	0.0192	0.0495	0.0356	0.0372	0.1134	0.2244	0.6740
0.0146	0.1706	0.0013	0.0284	0.0503	0.0256	0.0410	0.1228	0.3981	0.6472
0.0022	0.0382	0.0005	0.0063	0.0123	0.0076	0.0046	0.0243	0.0737	0.4501
0.0044	0.0449	0.0007	0.0103	0.0262	0.0170	0.0097	0.0391	0.1688	0.5900
0.0017	0.0201	0.0003	0.0034	0.0063	0.0047	0.0027	0.0249	0.0562	0.3411
0.0047	0.0507	0.0004	0.0103	0.0193	0.0126	0.0119	0.0866	0.1165	0.6332
0.0008	0.0105	0.0001	0.0009	0.0023	0.0010	0.0010	0.0092	0.0241	0.5656
0.0091	0.0402	0.0001	0.0148	0.0236	0.0208	0.0295	0.0311	0.0727	0.4063
0.0086	0.0751	0.0015	0.0235	0.0297	0.0297	0.0296	0.0589	0.1588	0.6976
0.0116	0.0919	0.0008	0.0195	0.0266	0.0170	0.0336	0.0544	0.1646	0.6963
0.0036	0.0398	0.0006	0.0093	0.0169	0.0122	0.0083	0.0529	0.0939	0.5314

Tabel 4.40 Distribusi Data 10 Klaster dan Nilai *DBI*

Klaster	Distribusi Data	Rasio	<i>DBI</i>
1	252 (56.25%)	1.0655	1.0085
2	18 (4.01%)	1.2815	
3	1 (0.22%)	0.4512	
4	120 (26.78%)	1.1416	
5	24 (5.35%)	1.1597	
6	12 (2.67%)	1.1597	
7	3 (0.66%)	0.5768	
8	4 (0.89%)	1.0776	
9	8 (1.78%)	1.2815	
10	6 (1.33%)	0.8903	


Sebaran hasil klastering data pada masing-masing klaster diperlihatkan pada Tabel 4.40. Klaster 1 sebanyak 252 dengan nilai rasio sebesar 1.0655, klaster 2 sebanyak 18 dengan nilai rasio 1.2815, klaster 3 sebanyak 1 dengan nilai rasio 0.4512, klaster 4 sebanyak 120 dengan nilai rasio 1.1416, klaster 5 sebanyak 24 dengan nilai rasio 1.1597, klaster 6 sebanyak 12 dengan nilai rasio 1.1597, klaster 7 sebanyak 3 dengan nilai rasio 0.5768, klaster 8 sebanyak 4 dengan nilai rasio 1.0776, klaster 9 sebanyak 8 dengan nilai rasio 1.2815, klaster 10 sebanyak 6

dengan nilai rasio 0.8903. Berdasarkan Tabel 4.40 nilai *DBI* 10 kluster sebesar 1.0085.

4.2 Hasil Validasi Kluster dan Penentuan Kluster Terbaik

Tabel 4.41 Nilai *DBI* 3 sampai 10 Kluster

Kluster	<i>DBI</i> KMeans	<i>DBI</i> SOM
3	1.1015	1.1367
4	1.0595	1.0538
5	1.3799	1.0820
6	1.2769	1.0333
7	1.2415	0.9704
8	1.149	1.1405
9	1.1483	1.1192
10	1.1502	1.0085



Gambar 4.1 Grafik Nilai *DBI* 3 sampai 10 Kluster

Dari uji coba yang telah dilakukan memperlihatkan adanya perbedaan grafik antara metode *K-Means* dan *SOM*. Hal ini dikarenakan inisialisasi awal antara metode *K-Means* dan *SOM* berbeda. Pada metode *K-Means* inisialisasi awal centroid awal dilakukan secara random sedangkan pada metode *SOM* inisialisasi awal dilakukan dengan menentukan bobot awal secara tetap. Selain itu distribusi data hasil clustering juga mempengaruhi hasil validasi cluster. Berdasarkan Grafik 4.1 dapat diamati bahwa nilai *DBI* paling minimum yaitu 0.9704 pada 7 kluster menggunakan metode *SOM*. Hal menyatakan bahwa 7 kluster menggunakan metode *SOM* adalah yang terbaik.

4.3 Visualisasi dan Analisis Hasil Klastering

Visualisasi hasil klastering Kabupaten/Kota akan dibatasi hanya dilakukan pada klastering yang mempunyai nilai *DBI* paling minimum dari seluruh nilai *DBI* yang ada. Hasil klastering minimum yang didapatkan adalah 7 klaster. Visualisasi dilakukan menggunakan grafik peta jaringan *SOM* dengan *u-matrix*. *U-matrix* merupakan representasi dari hasil klastering dengan *SOM* yang disebut *unified distance matrix*. *U-matrix* menggambarkan jarak antara data masukan terhadap bobot matrix jaringan *SOM* sesuai perhitungan fungsi jarak kemiripan data masukan. Jarak pada peta jaringan *SOM* diskalakan dengan menggunakan warna, jarak antar *neuron* digambarkan mulai warna merah tua sampai warna kuning. Parameter peta jaringan *SOM* dapat dilihat pada Tabel 4.42.

Tabel 4.42 Parameter Peta Jaringan *SOM*

Parameter	Keterangan
Algoritma Training	<i>Batch</i>
Bentuk Jaringan	<i>Shape</i>
Bentuk Topologi	<i>Hexa</i>
<i>Epochs</i>	200
<i>Learning Rate</i>	0.1
Jumlah <i>Neuron</i>	140
<i>Unit Map</i>	14 x 10

4.3.1 Visualisasi dan Analisis Berdasarkan Seluruh Indikator PDRB

Visualisasi klastering Kabupaten/Kota berdasarkan PDRB hanya akan dilakukan pada klastering yang mempunyai nilai *DBI* paling minimum dari keseluruhan nilai *DBI* yang diperoleh yaitu pada klastering dengan 7 klaster. Bobot akhir dapat dilihat di Tabel 4.46 dan distribusi keanggotaan masing-masing klaster dapat dilihat pada Tabel 4.43:


Tabel 4.43 Bobot Akhir 7 Klaster

Indikator	C1	C2	C3	C4	C5	C6	C7
PRT	0.0414	0.1717	0.0853	0.4967	0.4058	0.1944	0.0130
PTM	0.0050	0.0105	0.0058	0.0515	0.8255	0.0134	0.0000
IP	0.0047	0.0226	0.2274	0.0639	0.0359	0.6031	0.2906
PLG	0.0010	0.0028	0.1263	0.0127	0.0029	0.8176	0.2365
PAP	0.0144	0.0205	0.3204	0.0290	0.0296	0.0878	0.3530
KONS	0.0128	0.0304	0.2564	0.0612	0.0837	0.2342	0.8478
PER	0.0084	0.0236	0.1681	0.0426	0.0372	0.1114	0.6740
TRA	0.0192	0.0381	0.3448	0.0421	0.0410	0.1283	0.6472


PAM	0.0031	0.0094	0.0674	0.0101	0.0046	0.0227	0.4501
IK	0.0058	0.0125	0.1163	0.0189	0.0097	0.0575	0.5900
JK	0.0023	0.0045	0.0404	0.0057	0.0027	0.0327	0.3411
RE	0.0068	0.0132	0.0812	0.0166	0.0119	0.1069	0.6332
JP	0.0012	0.0014	0.0165	0.0017	0.0010	0.0150	0.5656
AP	0.0105	0.0172	0.0541	0.0210	0.0295	0.0365	0.4063
JPEN	0.0108	0.0279	0.1121	0.0250	0.0296	0.0830	0.6976
JKES	0.0149	0.0234	0.1198	0.0204	0.0336	0.0503	0.6963
JL	0.0045	0.0115	0.0705	0.0134	0.0083	0.0631	0.5314
Rata2	0.0098	0.0260	0.1302	0.0549	0.0937	0.1563	0.4690
Kategori	Rendah	Rendah	Tinggi	Tinggi	Tinggi	Tinggi	Tinggi

Tabel 4.44 Distribusi Data 7 Klaster

C1	C2	C3	C4	C5	C6	C7
273 (60.93%)	118 (26.33%)	12 (2.67%)	32 (7.14%)	3 (0.66%)	4 (0.89%)	6 (1.33%)




Gambar 4.2 Grafik *U-matrix* Seluruh Indikator




Gambar 4.3 Distribusi Data Seluruh Indikator

Berdasarkan Gambar 4.3 menunjukkan distribusi data berdasarkan warna yang berbeda. Bagian yang berwarna kuning menunjukkan tingkat perekonomian yang masih rendah. Sedangkan bagian yang berwarna orange, merah hingga merah gelap menunjukkan perekonomian yang tinggi. Untuk lebih jelas melihat karakteristik pola perekonomian masing-masing kluster diperlihatkan melalui visualisasi koordinat paralel.




Gambar 4.4 Visualisasi Kluster 1

Berdasarkan Gambar 4.4 menunjukkan karakteristik pola perekonomian pada kluster 1. Kluster ini nilainya lebih merata pada seluruh sektor dan cenderung rendah dengan nilai rata-rata 0.0098. Berdasarkan grafik tidak menunjukkan ada sektor yang dominan. Kluster ini didominasi oleh wilayah Indonesia bagian timur seperti Papua, Maluku, NTT, NTB, Kalimantan dan sebagian kecil di Sumatera.




Gambar 4.5 Visualisasi Kluster 2

Berdasarkan Gambar 4.5 menunjukkan karakteristik pola perekonomian pada kluster 2. Kluster ini hampir mirip polanya dengan kluster 1 nilainya lebih merata pada seluruh sektor dan cenderung rendah dengan nilai rata-rata 0.0260. Berdasarkan grafik tidak menunjukkan ada sektor yang dominan. Kluster ini didominasi oleh wilayah Indonesia bagian timur seperti Papua, Maluku, NTT, NTB dan sebagian di Kalimantan.



Gambar 4.6 Visualisasi Kluster 3


Berdasarkan Gambar 4.6 menunjukkan karakteristik pola perekonomian pada kluster 3. Kluster 3 dominan pada sektor industri pengolahan, pengadaan air, konstruksi dan transportasi. Kluster ini didominasi oleh wilayah industri seperti Bogor, Bekasi, Semarang, Sidoarjo, Balikpapan, Makasar, Medan dan Palembang.



Gambar 4.7 Visualisasi Kluster 4


Berdasarkan Gambar 4.7 menunjukkan karakteristik pola perekonomian pada kluster 4. Kluster 4 dominan pada sektor pertanian saja. Kluster ini

didominasi oleh wilayah di Jawa Barat seperti Sukabumi, Garut, Indramayu, Jawa Timur seperti Jember, Banyuwangi, Malang, Riau seperti Indragiri Hilir, Indragiri Hulu dan Lampung seperti Lampung Selatan, Lampung Timur, Lampung Tengah.




Gambar 4.8 Visualisasi Kluster 5

Berdasarkan Gambar 4.8 menunjukkan karakteristik pola perekonomian pada kluster 5. Kluster 5 dominan pada sektor pertanian dan pertambangan dengan nilai 0.4058 dan 0.8255. Kluster ini didominasi oleh wilayah seperti Kutai, Kutai Timur dan Bengkalis.



Gambar 4.9 Visualisasi Kluster 6

Berdasarkan Gambar 4.9 menunjukkan karakteristik pola perekonomian pada kluster 6. Kluster 6 dominan pada sektor industri pengolahan dan pengadaan listrik dengan nilai 0.6031 dan 0.8176. Kluster ini didominasi oleh wilayah seperti Karawang, Bekasi, Tangerang dan Cilegon.



Gambar 4.10 Visualisasi Klaster 7

Berdasarkan Gambar 4.10 menunjukkan karakteristik pola perekonomian pada klaster 7. Klaster 7 dominan pada sektor konstruksi, perdagangan, transportasi, penyediaan akomodasi, informasi komunikasi real estate, jasa perusahaan, jasa pendidikan, jasa kesehatan dan jasa lainnya dengan nilai diatas 0.4501. sedangkan sektor pertanian dan pertambangan nilainya sangat kecil. Klaster ini didominasi oleh wilayah seperti Jakarta dan Surabaya.

4.3.2 Visualisasi dan Analisis Berdasarkan Masing-Masing Indikator PDRB

Pada peta jaringan *SOM* yang direpresentasikan sebagai *u-matrix* di dalamnya terdapat informasi yang menyimpan karakteristik data tersebut. Untuk mengetahui secara lebih detail dilakukan juga proses klaster masing-masing indikator.

4.3.2.1 Visualisasi Indikator Pertanian


Tabel 4.45 Nilai *DBI* Indikator Pertanian

Klaster	<i>DBI</i>
3	0.0840
4	0.1178
5	0.1169
6	0.1025
7	0.1111
8	0.1693
9	0.1395
10	0.2040

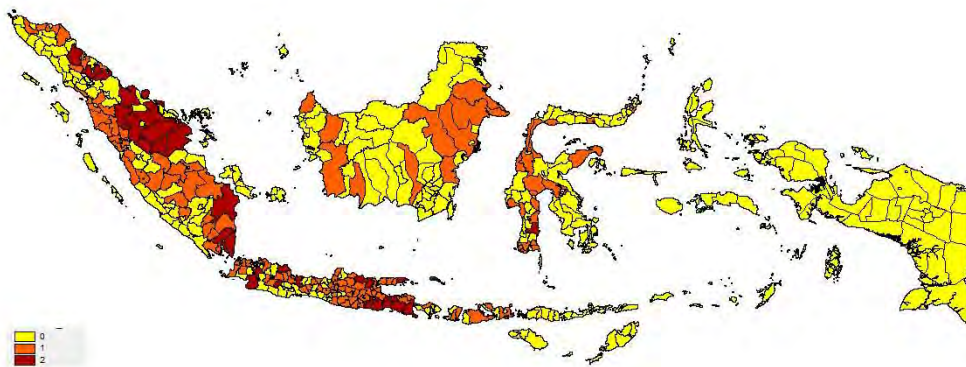
Berdasarkan Tabel 4.45 menunjukan bahwa klastering dengan 3 klaster adalah yang terbaik karena nilai *DBI* paling minimum dibandingkan dengan klaster yang lain.

Tabel 4.46 Bobot Akhir dan Distribusi Data 3 Klaster

Klaster	C1	C2	C3
Bobot Akhir	0.0410	0.1832	0.5063
Anggota	294 (65.62%)	122 (27.23%)	32 (7.14%)
Kategori	Rendah	Tinggi	Tinggi



Gambar 4.11 Grafik *U-matrik* Indikator Pertanian



Gambar 4.12 Peta Distribusi Data Indikator Pertanian

Dari Tabel 4.46 pada indikator pertanian menunjukan bahwa klaster 1 merupakan wilayah penghasil pertanian yang rendah, klaster 2 dan 3 adalah wilayah penghasil pertanian yang tinggi. Jika dilihat dari distribusi peta pada Gambar 4.12 klaster 1 didominasi oleh wilayah Indonesia timur seperti Papua, Maluku, NTT, NTB sebagian Sulawesi dan sebagian lagi Kalimantan. Klaster 2

dan kluster 3 didominasi wilayah di pulau Jawa, Sumatera dan sebagian Kalimantan.

4.3.2.2 Visualisasi Indikator Pertambahan


Tabel 4.47 Nilai *DBI* Indikator Pertambahan

Kluster	<i>DBI</i>
3	0.1702
4	0.1588
5	0.1531
6	0.2454
7	0.1573
8	0.1766
9	0.2274
10	0.1833

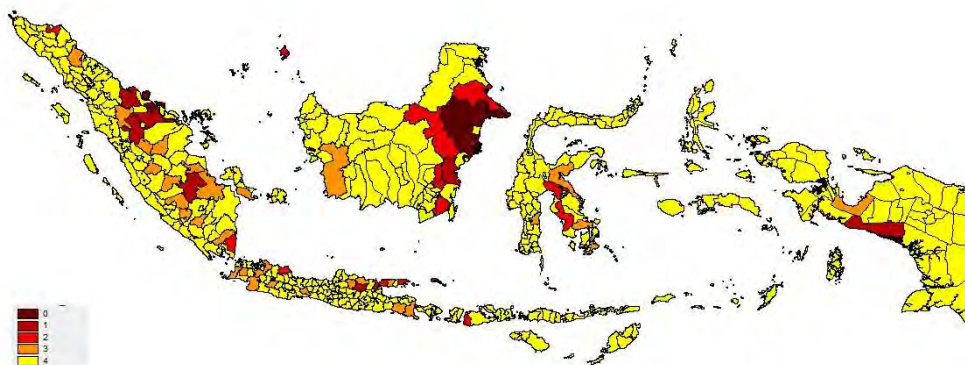
Berdasarkan Tabel 4.47 menunjukan bahwa klastering dengan 5 kluster adalah yang terbaik karena nilai *DBI* paling minimum dibandingkan dengan kluster yang lain.

Tabel 4.48 Bobot Akhir dan Distribusi Data 5 Kluster

Kluster	C1	C2	C3	C4	C5
Bobot Akhir	0.8255	0.2599	0.0761	0.0210	0.0019
Anggota	3 (0.66%)	7 (1.56%)	16 (3.57%)	44 (9.82%)	378 (84.37%)
Kategori	Tinggi	Tinggi	Tinggi	Tinggi	Rendah



Gambar 4.13 Grafik *U-matrix* Indikator Pertambahan



Gambar 4.14 Peta Distribusi Data Indikator Pertambangan

Dari Tabel 4.48 pada indikator pertambangan menunjukkan bahwa klaster 1 sampai 4 merupakan wilayah penghasil petambangan tinggi, sedangkan klaster 5 wilayah penghasil pertambangan yang rendah. Jika dilihat dari distribusi peta pada Gambar 4.14 klaster 1 sampai 4 berada di Kalimantan Timur seperti Kutai, Kutai Timur dan Bengkalis, wilayah Papua seperti Mimika, Kalimantan Timur seperti Paser, Kutai Barat dan Berau, Sumatera Riau seperti Siak, Rokan Hilir dan Rokan Hulu. Sedangkan klaster 5 merupakan wilayah bukan penghasil pertambangan.

4.3.2.3 Visualisasi Indikator Industri Pengolahan


Tabel 4.49 Nilai *DBI* Indikator Industri Pengolahan

Klaster	<i>DBI</i>
3	0.1984
4	0.1473
5	0.2203
6	0.2267
7	0.1546
8	0.1729
9	0.1496
10	0.1481


Berdasarkan Tabel 4.49 menunjukkan bahwa klastering dengan 4 klaster adalah yang terbaik karena nilai *DBI* paling minimum dibandingkan dengan klaster yang lain.

Tabel 4.50 Bobot Akhir dan Distribusi Data 4 Klaster

Klaster	C1	C2	C3	C4
Bobot Akhir	0.0088	0.1792	0.4247	1.0000
Anggota	417 (93.08%)	21 (4.68%)	9 (2.00%)	1 (0.22%)
Kategori	Rendah	Tinggi	Tinggi	Tinggi



Gambar 4.15 Grafik *U-matrix* Indikator Industri Pengolahan



Gambar 4.16 Peta Distribusi Data Indikator Industri Pengolahan

Dari Tabel 4.50 pada indikator industri pengolahan menunjukkan bahwa klaster 1 merupakan wilayah industri pengolahan yang rendah, klaster 2 sampai 4 merupakan wilayah industri pengolahan yang tinggi. Jika dilihat dari distribusi peta pada Gambar 4.16 klaster 2 sampai 4 berada di pulau Jawa seperti Jakarta, Bekasi, Karawang, Bogor, Sidoarjo dan Kota Surabaya.

4.3.2.4 Visualisasi Indikator Pengadaan Listrik dan Gas


Tabel 4.51 Nilai *DBI* Indikator Pengadaan Listrik dan Gas

Klaster	<i>DBI</i>
3	0.1645
4	0.1550
5	0.1729
6	0.1036
7	0.1449
8	0.1103
9	0.1096
10	0.1386

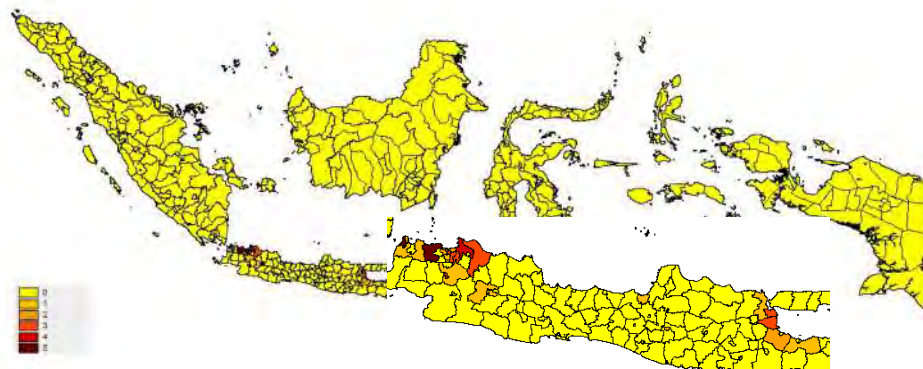
Berdasarkan Tabel 4.51 menunjukan bahwa klastering dengan 6 klaster adalah yang terbaik karena nilai *DBI* paling minimum dibandingkan dengan klaster yang lain.

Tabel 4.52 Bobot Akhir dan Distribusi Data 6 Klaster

Klaster	C1	C2	C3	C4	C5	C6
Bobot Akhir	0.0015	0.0372	0.1635	0.3391	0.6605	0.9874
Anggota	420 (93.75%)	13 (2.90%)	4 (0.89%)	8 (1.78%)	1 (0.22%)	2 (0.44%)
Kategori	Rendah	Tinggi	Tinggi	Tinggi	Tinggi	Tinggi



Gambar 4.17 Grafik *U-matrix* Indikator Pengadaan Listrik dan Gas



Gambar 4.18 Peta Distribusi Data Indikator Pengadaan Listrik dan Gas

Dari Tabel 4.52 pada indikator pengadaan listrik dan gas menunjukkan bahwa klaster 1 merupakan wilayah pengadaan listrik dan gas yang rendah, klaster 2 sampai 6 merupakan wilayah pengadaan listrik dan gas yang tinggi. Jika dilihat dari distribusi peta pada Gambar 4.18 klaster 2 sampai 6 didominasi oleh wilayah di pulau Jawa seperti Jakarta, Bekasi, Tangerang, Cilegon, Karawang, Bogor, Sidoarjo, Gresik dan Kota Surabaya.

4.3.2.5 Visualisasi Indikator Industri Pengadaan Air


Tabel 4.53 Nilai *DBI* Indikator Pengadaan Air

Klaster	<i>DBI</i>
3	0.1196
4	0.1131
5	0.1228
6	0.1220
7	0.1164
8	0.1158
9	0.1165
10	0.1147

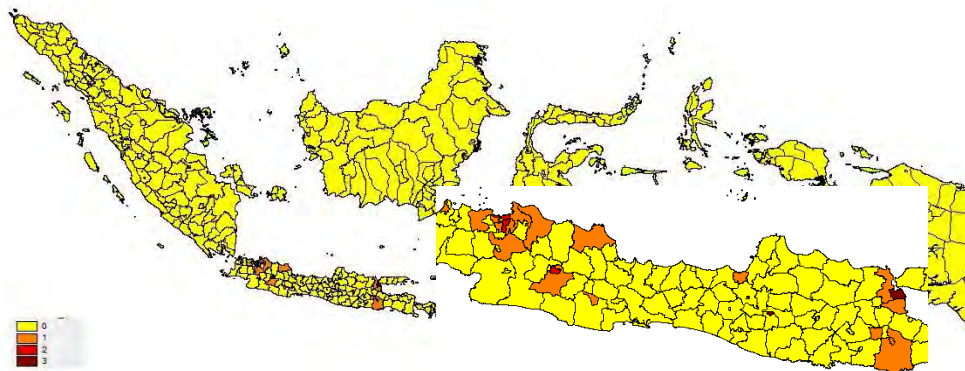
Berdasarkan Tabel 4.53 menunjukkan bahwa klastering dengan 4 klaster adalah yang terbaik karena nilai *DBI* paling minimum dibandingkan dengan klaster yang lain.

Tabel 4.54 Bobot Akhir dan Distribusi Data 4 Klaster

Klaster	C1	C2	C3	C4
Bobot Akhir	0.0138	0.1385	0.3941	0.9757
Anggota	413 (92.18%)	25 (5.58%)	8 (1.78%)	2 (0.44)
Kategori	Rendah	Tinggi	Tinggi	Tinggi



Gambar 4.19 Grafik *U-matrix* Indikator Pengadaan Air



Gambar 4.20 Peta Distribusi Data Indikator Pengadaan Air

Dari Tabel 4.54 pada indikator pengadaan air menunjukkan bahwa klaster 1 merupakan wilayah pengadaan air rendah, klaster 2 sampai 4 merupakan wilayah pengadaan air yang tinggi, Jika dilihat dari distribusi peta pada Gambar 4.20 klaster 2 sampai 4 didominasi oleh wilayah di pulau Jawa seperti Jakarta, Bekasi, Tangerang, Cilegon, Karawang, Bogor, Bandung, Sidoarjo, Gresik dan Kota Surabaya.

4.3.2.6 Visualisasi Indikator Konstruksi

Tabel 4.55 Nilai *DBI* Indikator Konstruksi


Klaster	<i>DBI</i>
3	0.1202
4	0.1390
5	0.1819
6	0.1942

7	0.2060
8	0.1706
9	0.1800
10	0.1694


Berdasarkan Tabel 4.55 menunjukan bahwa klastering dengan 3 klaster adalah yang terbaik karena nilai *DBI* paling minimum dibandingkan dengan klaster yang lain.

Tabel 4.56 Bobot Akhir dan Distribusi Data 3 Klaster

Klaster	C1	C2	C3
Bobot Akhir	0.0186	0.2503	0.8478
Anggota	422 (94.19%)	19 (4.24%)	7 (1.56%)
Kategori	Rendah	Tinggi	Tinggi



Gambar 4.21 Grafik *U-matrix* Indikator Konstruksi



Gambar 4.22 Peta Distribusi Data Indikator Konstruksi

Dari Tabel 4.56 pada indikator konstruksi menunjukkan bahwa klaster 1 merupakan wilayah konstruksi rendah, klaster 2 dan 3 merupakan wilayah konstruksi yang tinggi. Jika dilihat dari distribusi peta pada Gambar 4.22 klaster 2 dan 3 didominasi oleh wilayah di pulau Jawa seperti Jakarta, Bekasi, Tangerang, Karawang, Bogor, Bandung, Sidoarjo, Gresik, pasuruan, Malang dan Kota Surabaya.

4.3.2.7 Visualisasi Indikator Perdagangan


Tabel 4.57 Nilai *DBI* Indikator Perdagangan

Klaster	<i>DBI</i>
3	0.1394
4	0.1893
5	0.2291
6	0.2194
7	0.2736
8	0.1786
9	0.1762
10	0.1821

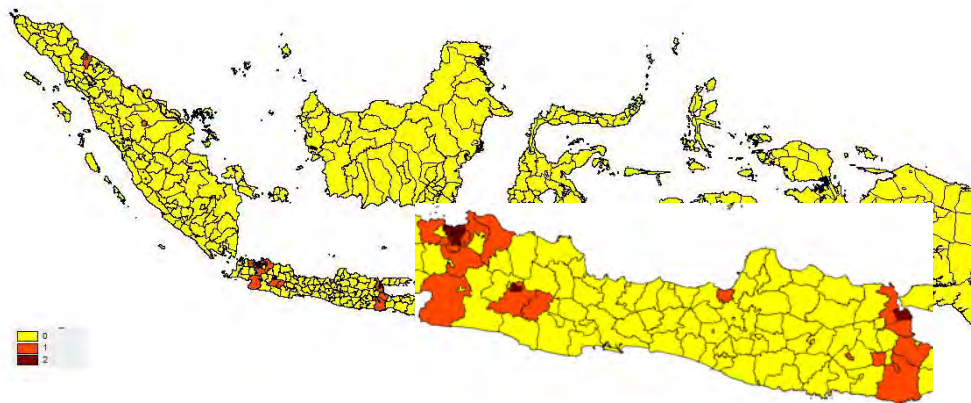
Berdasarkan Tabel 4.57 menunjukkan bahwa klastering dengan 3 klaster adalah yang terbaik karena nilai *DBI* paling minimum dibandingkan dengan klaster yang lain.

Tabel 4.58 Bobot Akhir dan Distribusi Data 3 Klaster

Klaster	C1	C2	C3
Bobot Akhir	0.0133	0.1363	0.6341
Anggota	418 (93.30%)	23 (5.13%)	7 (1.56%)
Kategori	Rendah	Tinggi	Tinggi



Gambar 4.23 Grafik *U-matrix* Indikator Perdagangan



Gambar 4.24 Peta Distribusi Data Indikator Perdagangan

Dari Tabel 4.58 pada indikator perdagangan menunjukkan bahwa klaster 1 merupakan wilayah perdagangan yang rendah, klaster 2 dan 3 merupakan wilayah perdagangan yang tinggi. Jika dilihat dari distribusi peta pada Gambar 4.24 klaster 2 dan 3 didominasi oleh wilayah di pulau Jawa seperti Jakarta, Bekasi, Tangerang, Karawang, Bogor, Sukabumi, Bandung, Sidoarjo, Gresik, Pasuruan, Malang, Kota Kediri dan Kota Surabaya.

4.3.2.8 Visualisasi Indikator Transportasi

Tabel 4.59 Nilai *DBI* Indikator Transportasi


Klaster	<i>DBI</i>
3	0.1369
4	0.1301
5	0.1271

6	0.1258
7	0.1221
8	0.1220
9	0.1214
10	0.1174

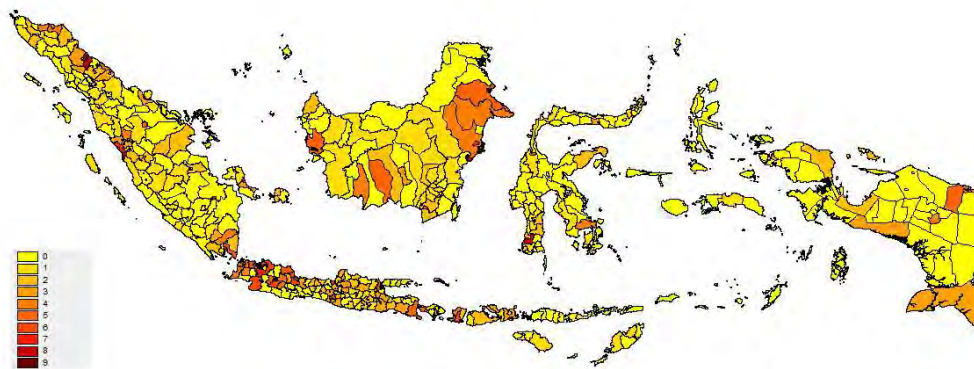
Berdasarkan Tabel 4.59 menunjukkan bahwa klastering dengan 10 klaster adalah yang terbaik karena nilai *DBI* paling minimum dibandingkan dengan klaster yang lain.

Tabel 4.60 Bobot Akhir dan Distribusi Data 10 Klaster

Klaster	Bobot Akhir	Anggota	Kategori
C1	0.0035	166 (37.05%)	Rendah
C2	0.0121	103 (22.99%)	Rendah
C3	0.0232	52 (11.60%)	Rendah
C4	0.0377	39 (8.70%)	Rendah
C5	0.0559	32 (7.14%)	Tinggi
C6	0.0831	16 (3.57%)	Tinggi
C7	0.1253	17 (3.79%)	Tinggi
C8	0.2189	8 (1.78%)	Tinggi
C9	0.3879	9 (2.00%)	Tinggi
C10	0.7859	6 (1.33%)	Tinggi



Gambar 4.25 Grafik *U-matrix* Indikator Transportasi



Gambar 4.26 Peta Distribusi Data Indikator Transportasi

Dari Tabel 4.60 pada indikator transportasi menunjukkan bahwa klaster 1 sampai 4 merupakan wilayah transportasi yang rendah, klaster 5 sampai 10 merupakan wilayah transportasi yang tinggi. Jika dilihat dari distribusi peta pada Gambar 4.26 indikator transportasi sedang hingga tinggi, lebih merata pada seluruh wilayah Indonesia. Sedangkan transportasi rendah terbanyak berada di Indonesia timur dan sebagian di Sumatera dan Kalimantan.

4.3.2.9 Visualisasi Indikator Penyediaan Akomodasi Makan


Tabel 4.61 Nilai *DBI* Indikator Penyediaan Akomodasi Makan

Klaster	<i>DBI</i>
3	0.0966
4	0.1510
5	0.2327
6	0.1244
7	0.1573
8	0.1550
9	0.2390
10	0.2690

Berdasarkan Tabel 4.61 menunjukkan bahwa klastering dengan 3 klaster adalah yang terbaik karena nilai *DBI* paling minimum dibandingkan dengan klaster yang lain.

Tabel 4.62 Bobot Akhir dan Distribusi Data 3 Klaster

Klaster	C1	C2	C3
Bobot Akhir	0.0066	0.3140	1.0000
Anggota	440 (98.21%)	7 (1.56%)	1 (0.22%)
Kategori	Rendah	Tinggi	Tinggi



Gambar 4.27 Grafik *U-matrix* Indikator Akomodasi Makan



Gambar 4.28 Peta Distribusi Indikator Akomodasi Makan

Dari Tabel 4.62 pada indikator akomodasi makan menunjukkan bahwa klaster 1 merupakan wilayah penyedia akomodasi makan rendah, klaster 2 dan 3 merupakan wilayah penyedia akomodasi makan tinggi karena wilayah ini adalah daerah pariwisata dan pusat perekonomian. Jika dilihat dari distribusi peta pada Gambar 4.28 indikator akomodasi makan sedang hingga tinggi, berada di wilayah kota-kota besar seperti Jakarta, Surabaya, Denpasar dan Yogyakarta.

4.3.2.10 Visualisasi Indikator Informasi Komunikasi

Tabel 4.63 Nilai *DBI* Indikator Informasi Komunikasi


Klaster	<i>DBI</i>
3	0.1889
4	0.2082
5	0.2352
6	0.1663

7	0.1617
8	0.2058
9	0.1648
10	0.1901

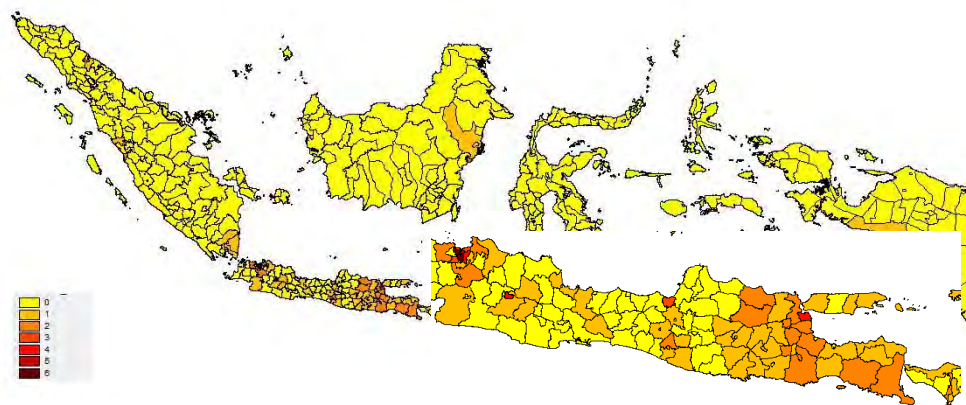
Berdasarkan Tabel 4.63 menunjukan bahwa klastering dengan 7 klaster adalah yang terbaik karena nilai *DBI* paling minimum dibandingkan dengan klaster yang lain.

Tabel 4.64 Bobot Akhir dan Distribusi Data 7 Klaster

Klaster	Bobot Akhir	Anggota	Kategori
C1	0.0039	353 (78.79%)	Rendah
C2	0.0237	60 (13.39%)	Tinggi
C3	0.0595	23 (5.13%)	Tinggi
C4	0.1693	6 (1.33%)	Tinggi
C5	0.3945	3 (0.33%)	Tinggi
C6	0.6744	1 (0.22%)	Tinggi
C7	0.9759	2 (0.44%)	Tinggi



Gambar 4.29 Grafik *U-matrix* Indikator Informasi Komunikasi



Gambar 4.30 Peta Distribusi Data Indikator Informasi Komunikasi

Dari Tabel 4.64 pada indikator informasi komunikasi menunjukkan bahwa klaster 1 merupakan wilayah informasi komunikasi yang rendah, klaster 2 sampai 7 merupakan wilayah informasi komunikasi tinggi. Jika dilihat dari distribusi peta pada Gambar 4.30. indikator informasi komunikasi sedang hingga tinggi, didominasi oleh wilayah di pulau Jawa seperti Jakarta, Bandung, Bogor, Surabaya, Malang, Pasuruan, Kediri, Denpasar dan Yogyakarta.

4.3.2.11 Visualisasi Indikator Jasa Keuangan


Tabel 4.65 Nilai *DBI* Indikator Jasa Keuangan

Klaster	<i>DBI</i>
3	0.0813
4	0.1020
5	0.0612
6	0.1167
7	0.0658
8	0.0763
9	0.0729
10	0.0744


Berdasarkan Tabel 4.65 menunjukkan bahwa klastering dengan 5 klaster adalah yang terbaik karena nilai *DBI* paling minimum dibandingkan dengan klaster yang lain.

Tabel 4.66 Bobot Akhir dan Distribusi Data 5 Klaster

Klaster	C1	C2	C3	C4	C5
Bobot Akhir	0.0033	0.0538	0.2026	0.5397	1.0000
Anggota	432 (96.42%)	12 (2.67%)	2 (0.44%)	1 (0.22%)	1 (0.22%)
Kategori	Rendah	Tinggi	Tinggi	Tinggi	Tinggi



Gambar 4.31 Grafik *U-matrix* Indikator Jasa Keuangan



Gambar 4.32 Peta Distribusi Data Indikator Jasa Keuangan

Dari Tabel 4.66 pada indikator jasa keuangan menunjukkan bahwa klaster 1 merupakan wilayah jasa keuangan yang rendah, klaster 2 sampai 5 merupakan wilayah jasa keuangan tinggi. Jika dilihat dari distribusi peta pada Gambar 4.32. wilayah ini didominasi oleh kota-kota besar di Jawa seperti Jakarta, Tangerang, Bandung, dan Kota Surabaya.

4.3.2.12 Visualisasi Indikator Real Estate


Tabel 4.67 Nilai *DBI* Indikator Real Estate

Klaster	<i>DBI</i>
3	0.2346
4	0.2395
5	0.2270
6	0.2408
7	0.2273
8	0.2676
9	0.2797
10	0.2829


Berdasarkan Tabel 4.67 menunjukan bahwa klastering dengan 5 klaster adalah yang terbaik karena nilai *DBI* paling minimum dibandingkan dengan klaster yang lain.

Tabel 4.68 Bobot Akhir dan Distribusi Data 5 Klaster

Klaster	C1	C2	C3	C4	C5
Bobot Akhir	0.0079	0.0907	0.3103	0.5621	0.9091
Anggota	426 (95.08%)	14 (3.12%)	3 (0.66%)	3 (0.66%)	2 (0.44%)
Kategori	Rendah	Tinggi	Tinggi	Tinggi	Tinggi



Gambar 4.33 Grafik *U-matrix* Indikator Real Estate



Gambar 4.34 Peta Distribusi Data Indikator Real Estate

Dari Tabel 4.68 pada indikator real estate menunjukkan bahwa klaster 1 merupakan wilayah real estate yang rendah, klaster 2 sampai 5 merupakan wilayah real estate tinggi. Jika dilihat dari distribusi peta pada Gambar 4.34, wilayah ini didominasi oleh kota-kota besar seperti Jakarta, Serang, Tangerang, Bekasi, Semarang, Sleman, Bandung, dan Kota Surabaya.

4.3.2.13 Visualisasi Indikator Jasa Perusahaan


Tabel 4.69 Nilai *DBI* Indikator Jasa Perusahaan

Klaster	<i>DBI</i>
3	0.1646
4	0.1186
5	0.1711
6	0.1229
7	0.1393
8	0.1519
9	0.1614
10	0.1518


Berdasarkan Tabel 4.69 menunjukkan bahwa klastering dengan 4 klaster adalah yang terbaik karena nilai *DBI* paling minimum dibandingkan dengan klaster yang lain.

Tabel 4.70 Bobot Akhir dan Distribusi Data 4 Klaster

Klaster	C1	C2	C3	C4
Bobot Akhir	0.0019	0.2292	0.4219	1.0000
Anggota	442 (95.08%)	1 (0.22%)	3 (0.66%)	2 (0.44%)
Kategori	Rendah	Tinggi	Tinggi	Tinggi



Gambar 4.35 Grafik *U-matrix* Indikator Jasa Perusahaan



Gambar 4.36 Peta Distribusi Data Indikator Jasa Perusahaan

Dari Tabel 4.70 pada indikator jasa perusahaan menunjukkan bahwa klaster 1 merupakan wilayah jasa perusahaan yang rendah, klaster 2 sampai 4 merupakan wilayah jasa perusahaan tinggi. Jika dilihat dari distribusi peta pada Gambar 4.36. wilayah ini didominasi oleh kota-kota besar seperti Jakarta dan Kota Surabaya.

4.3.2.14 Visualisasi Indikator Administrasi Pemerintahan


Tabel 4.71 Nilai *DBI* Indikator Administrasi Pemerintahan

Klaster	<i>DBI</i>
3	0.1538
4	0.2491
5	0.1363
6	0.2152
7	0.1309
8	0.1393
9	0.1370
10	0.1488


Berdasarkan Tabel 4.71 menunjukkan bahwa klastering dengan 7 klaster adalah yang terbaik karena nilai *DBI* paling minimum dibandingkan dengan klaster yang lain.

Tabel 4.72 Bobot Akhir dan Distribusi Data 7 Klaster

Klaster	Bobot Akhir	Anggota	Kategori
C1	0.0063	223 (49.77%)	Rendah
C2	0.0145	139 (31.02%)	Rendah
C3	0.0281	59 (13.16%)	Tinggi
C4	0.0591	18 (4.01%)	Tinggi
C5	0.1189	6 (1.33%)	Tinggi
C6	0.3061	1 (0.22%)	Tinggi
C7	0.8753	2 (0.44%)	Tinggi



Gambar 4.37 Grafik *U-matrix* Indikator Administrasi Pemerintahan



Gambar 4.38 Peta Distribusi Data Indikator Administrasi Perkantoran

Dari Tabel 4.72 pada indikator administrasi perkantoran menunjukkan bahwa klaster 1 dan 2 merupakan wilayah administrasi perkantoran yang rendah,

klaster 3 sampai 7 merupakan wilayah administrasi perkantoran tinggi. Jika dilihat dari distribusi peta pada Gambar 4.38. klaster 3 sampai 7 merata berada di seluruh Indonesia. Sedangkan klaster 1 dan 2 sebgin berada di Papua dan Kalimantan.

4.3.2.15 Visualisasi Indikator Jasa Pendidikan


Tabel 4.73 Nilai *DBI* Indikator Jasa Pendidikan

Klaster	<i>DBI</i>
3	0.1738
4	0.1511
5	0.1736
6	0.1386
7	0.1550
8	0.1485
9	0.1405
10	0.1526

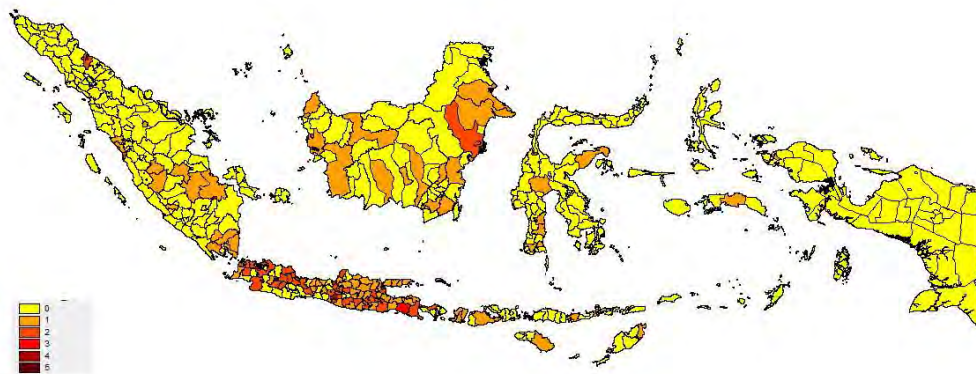
Berdasarkan Tabel 4.73 menunjukan bahwa klastering dengan 6 klaster adalah yang terbaik karena nilai *DBI* paling minimum dibandingkan dengan klaster yang lain.

Tabel 4.74 Bobot Akhir dan Distribusi Data 6 Klaster

Klaster	C1	C2	C3	C4	C5	C6
Bobot Akhir	0.0064	0.0260	0.0599	0.1574	0.4121	0.8330
Anggota	282 (62.94%)	105 (23.43%)	45 (10.04%)	9 (2.00%)	3 (0.66%)	4 (0.89%)
Kategori	Rendah	Rendah	Tinggi	Tinggi	Tinggi	Tinggi



Gambar 4.39 Grafik *U-matrix* Indikator Jasa Pendidikan



Gambar 3.40 Peta Distribusi Data Indikator Jasa Pendidikan

Dari Tabel 4.74 pada indikator jasa pendidikan menunjukkan bahwa klaster 1 dan 2 merupakan wilayah jasa pendidikan yang rendah, klaster 3 sampai 6 merupakan wilayah jasa pendidikan tinggi. Jika dilihat dari distribusi peta pada Gambar 4.40 klaster 3 sampai 6 didominasi oleh wilayah di pulau Jawa dan sebagian Sumatera. Sedangkan klaster 1 dan 2 terbanyak berada di Papua, Maluku, NTT, NTB sebagian Kalimantan dan sebagian Sumatera.

4.3.2.16 Visualisasi Indikator Jasa Kesehatan

Tabel 4.75 Nilai *DBI* Indikator Jasa Kesehatan


Klaster	<i>DBI</i>
3	0.2214
4	0.1829
5	0.1743
6	0.2438
7	0.1762
8	0.1985
9	0.1609
10	0.1887

Berdasarkan Tabel 4.75 menunjukkan bahwa klastering dengan 9 klaster adalah yang terbaik karena nilai *DBI* paling minimum dibandingkan dengan klaster yang lain.

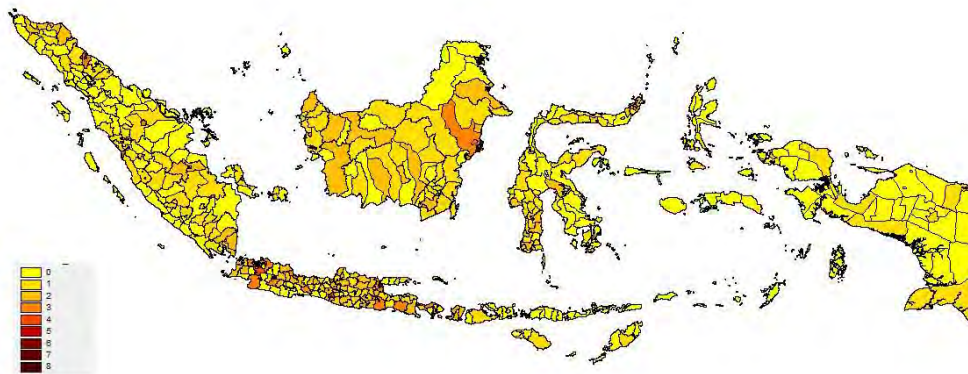
Tabel 4.76 Bobot Akhir dan Distribusi Data 9 Klaster

Klaster	Bobot Akhir	Anggota	Kategori
C1	0.0055	178 (39.73%)	Rendah
C2	0.0144	136 (30.35%)	Rendah

C3	0.0263	79 (17.63%)	Rendah
C4	0.0575	31 (6.91%)	Tinggi
C5	0.1041	14 (3.12%)	Tinggi
C6	0.2604	3 (0.66%)	Tinggi
C7	0.3724	2 (0.44%)	Tinggi
C8	0.6208	3 (0.66%)	Tinggi
C9	0.9502	2 (0.44%)	Tinggi



Gambar 4.41 Grafik *U-matrix* Indikator Jasa Kesehatan



Gambar 4.42 Peta Distribusi Data Indikator Jasa Kesehatan

Dari Tabel 4.76 pada indikator jasa kesehatan menunjukkan bahwa klaster 1 sampai 3 merupakan wilayah jasa kesehatan yang rendah, klaster 4 dan 9 merupakan wilayah jasa kesehatan tinggi. Jika dilihat dari distribusi peta pada Gambar 4.42. klaster 6 sampai 9 didominasi oleh wilayah di pulau Jawa. Klaster 4 dan 5 berada di Kalimantan, Sumatera dan Sulawesi. Klaster 1 sampai 3 di Papua, Maluku, NTT dan NTB.

4.3.2.17 Visualisasi Indikator Jasa Lainnya


Tabel 4.77 Nilai *DBI* Indikator Jasa Lainnya

Klaster	<i>DBI</i>
3	0.2774
4	0.1392
5	0.1456
6	0.1130
7	0.1324
8	0.1507
9	0.1169
10	0.1238


Berdasarkan Tabel 4.77 menunjukan bahwa klastering dengan 6 klaster adalah yang terbaik karena nilai *DBI* paling minimum dibandingkan dengan klaster yang lain.

Tabel 4.78 Bobot Akhir dan Distribusi Data 6 Klaster

Klaster	C1	C2	C3	C4	C5	C6
Bobot Akhir	0.0034	0.0227	0.0720	0.3808	0.6650	1.0000
Anggota	353 (78.79%)	72 (16.07%)	16 (3.57%)	5 (1.11%)	1 (0.22%)	1 (0.22%)
Kategori	Rendah	Tinggi	Tinggi	Tinggi	Tinggi	Tinggi



Gambar 4.43 Grafik *U-matrix* Indikator Jasa Lainnya



Gambar 4.43 Peta Distribusi Data Indikator Jasa Lainnya

Dari Tabel 4.78 pada indikator jasa lainnya menunjukkan bahwa klaster 1 merupakan wilayah jasa lainnya rendah, klaster 2 sampai 6 merupakan wilayah jasa lainnya tinggi. Jika dilihat dari distribusi peta pada Gambar 4.43. klaster 2 sampai 6 didominasi oleh wilayah di pulau Jawa. Sedangkan klaster 1 hampir berada di seluruh wilayah Indonesia.

BAB 5

KESIMPULAN

5.1 Kesimpulan

Dari penelitian yang telah dilakukan dapat diambil beberapa kesimpulan sebagai berikut:

1. Metode kluster menggunakan *K-Means* dan *Self-Organizing Maps (SOM)* dapat digunakan untuk melakukan klustering data Kabupaten/Kota berdasarkan seluruh indikator PDRB. Berdasarkan penelitian yang telah dilakukan SOM lebih baik dibandingkan *K-Means*, karena dari hasil validasi kluster SOM memiliki nilai DBI paling minimum dibandingkan *K-Means*.
2. Klaster 1 dan klaster 2 merupakan kluster yang memiliki kategori perekonomian paling rendah karena memiliki nilai di bawah rata-rata dari setiap indikator PDRB. Presentase keanggotaan 87.26% yang didominasi oleh wilayah Indonesia bagian timur seperti Papua, Maluku, NTT, NTB dan sebagian Kalimantan. Jika ingin melakukan peningkatan kesejahteraan diharapkan pada klaster 1 dan 2 karena memiliki tingkat perekonomian paling rendah di Indonesia.
3. Klaster 3 dengan presentase keanggotaan 2.67% merupakan kluster yang memiliki kategori perekonomian tinggi. Klaster ini dominan pada sektor industri pengolahan, pengadaan listrik dan gas, pengadaan air, konstruksi dan transportasi, sedangkan pada sektor-sektor yang lain masih rendah. Wilayah ini bisa dikatakan kota-kota besar seperti Bandung, Bekasi, Sidoarjo, Badung, Balikpapan, Makassar, Medan, Palembang dan Batam.
4. Klaster 4 dengan presentase keanggotaan 7.14% merupakan kluster yang memiliki kategori perekonomian tinggi. Klaster ini dominan pada sektor pertanian, sedangkan pada sektor-sektor yang lain masih rendah. Jika ingin melakukan program peningkatan sektor pertanian diharapkan pada klaster 4. Klaster ini berada di pulau Jawa dan Sebagian Sumatera seperti Sukabumi, Garut, Indramayu, Brebes, Blitar, Malang, Jember, Banyuwangi, Lumajang, Probolinggo, Indragiri hilir, Pelalawan, Siak, Kampar, Rokan hulu, Rokan hilir, Lampung Selatan, Lampung Tengah serta Lampung Timur.

5. Klaster 5 dengan presentase keanggotaan 0.66% merupakan klaster yang memiliki kategori perekonomian tinggi dominan pada sektor pertanian dan pertambangan, sedangkan pada sektor-sektor yang lain masih rendah. Jika ingin melakukan program peningkatan sektor pertanian dan pertambangan diharapkan pada klaster 5. Wilayah ini diantaranya adalah Kutai, Kutai Timur serta Bengkalis.
6. Klaster 6 dengan presentase keanggotaan 0.89% merupakan klaster yang memiliki kategori perekonomian tinggi dominan pada sektor industri pengolaha dan pengadaan listrik dan gas, sedangkan pada sektor-sektor yang lain masih rendah. Jika ingin melakukan program peningkatan sektor industri diharapkan pada klaster 6. Wilayah ini diantaranya adalah Karawang, Bekasi, Tangerang serta Cilegon.
7. Klaster 7 dengan presentase keanggotaan 1.33% merupakan klaster yang memiliki kategori perekonomian paling tinggi dominan hamper pada seluruh sektor, hanya pada sektor pertanian dan pertambangan saja klaster ini nilainya sangat rendah. Klaster ini merupakan wilayah pusat perekonomian di Indonesia yaitu Jakarta dan Surabaya.

DAFTAR PUSTAKA

- Arsyad, L. (2010). “Ekonomi Pembangunan”, Edisi Kelima. UPP STIM YKPN, Yogyakarta .
- BPS, (2015), “Produk Domestik Regional Bruto Menurut Lapangan Usaha 2010-2014”, Publikasi.
- Daniel A Kiem, (2002), “*Information Visialization and Visual Data Mining*”, IEEE TRANSACTIONS ON VISUALIZATION AND COMPUTER GRAPHICS.
- Hilmi, MN. Dkk, (2015), “Pemetaan Preferensi Mahasiswa Baru Dalam Memilih Jurusan Menggunakan *Artificial Neural Network (ANN)* dengan Algoritma *Self-Organizing Maps (SOM)*”, Jurnal Gaussian, Vol.4, No.1, Hal 53-60.
- Irhamni, Firli, dkk, (2012), “Optimalisasi Pengelompokkan Kecamatan Berdasarkan Indikator Pendidikan Menggunakan Metode Clustering dan Davies Bouldin Index”, Seminar Nasional Sains dan Teknologi Universitas Muhammadiyah.
- Irman Hermadi, dkk “Clustering Menggunakan *Self-Organizing Map* (Studi Kasus: Data PPMB IPB)”,
- Kusumadewi, S. (2004), “Membangun Jaringan Syaraf Tiruan (menggunakan MATLAB & Excel Link)”, Yogyakarta: Penerbit Graha Ilmu.
- Maimon, Oded, Rokach, Lior, (2011), “Data Mining and Knowledge Discovery Handbook”, Second Edition
- Muchfudhoh, S dan Wahyuningsih N, (2013), “Analisis *Cluster* Kabupaten/Kota Berdasarkan Pertumbuhan Ekonomi Jawa Timur”, Jurnal Sains dan Seni POMITS Vol.2, No.1, 2337-3520.
- Nugroho, AC. Dkk, (2012), “Clustering Kelompok Swadaya Masyarakat (KSM) Dalam Menentukan Kebijakan Bantuan Badan Pemberdayaan Masyarakat di Kota Surabaya Dengan Menggunakan Metode *Self-Organizing Maps (SOM)* dan K-Means”, Jurnal Teknik POMITS, Vol.1 No.1, 1-6.
- Prasetyo, Eko. (2012), “Data Mining Konsep dan Aplikasi Menggunakan MATLAB”. Yogyakarta: Penerbit ANDI.

- Prasetyo, Eko. (2014), “Data Mining Mengolah Data Menjadi Informasi menggunakan MATLAB”, Yogyakarta: Penerbit ANDI.
- Rizal, AS dan Hakim Fajriya RB, (2015), “Metode K-Means *Cluster* dan *Fuzzy C-Means Cluster*”, Seminar Nasional Matematika dan Pendidikan Matematika UMS.
- Santosa, Budi. (2007), “Data Mining Teknik Pemanfaatan Data Untuk Keperluan Bisnis”, Yogyakarta: Penerbit Graha Ilmu.
- Satoto, BD. Dkk, (2015), “Pengelompokan Tingkat Kesehatan Masyarakat Menggunakan *Self-Organizing Maps (SOM)* Dengan *Cluster Validation DBI dan I-Dunn*”, Seminar Nasional Aplikasi Teknologi Informasi (SNATi), Yogyakarta.
- Sjafrizal. (2012), “Ekonomi Wilayah dan Perkotaan”, PT Rajagrafindo Persada, Jakarta

BIOGRAFI PENULIS



Agung Jaelanie, Mahasiswa Magister di Institut Teknologi Sepuluh Nopember (ITS), Fakultas Teknologi Industri, Jurusan Teknik Elektro, Bidang Keahlian Telematika CIO. Merupakan salah satu penerima Beasiswa Dalam Negeri Program Studi Chief Information Officer (CIO) Tahun 2014 dari Kementerian Komunikasi dan Informatika (KOMINFO) RI. Lahir di Martapura, Kalimantan Selatan pada tanggal 21 Maret 1986. Anak pasangan Agus Martono S dan Anik Sriwenie. Sejak Januari 2010 memulai berkarir sebagai Guru Pegawai Negeri

Sipil di Kabupaten Kotawaringin Timur, Kalimantan Tengah.

Riwayat Pendidikan

SD	: SDN 14 Sampit, Kalimantan Tengah 1998
SMP	: SMPN 2 Sampit, Kalimantan Tengah 2001
SMK	: Teknik Otomotif - SMKN 2 Sampit, Kalimantan Tengah 2005
D-4	: Teknik Informatika - Politeknik Elektronika Negeri Surabaya – Institut Teknologi Sepuluh Nopember (PENS-ITS) 2009

Riwayat Pekerjaan

2010 -2013	: Mengajar bidang Teknik Multimedia di SMKN 2 Pulau Hanaut, Kalimantan Tengah
2013-Sekarang	: Mengajar bidang Teknik Komputer dan Jaringan (TKJ) di SMKN 2 Sampit, Kalimantan Tengah
2013-Sekarang	: Mengajar bidang Teknik Komputer dan Jaringan di Program Studi Di Luar Domisili (Politeknik Negeri Banjarmasin)